



ZAAWANSOWANE MODELOWANIE ORAZ ALGORYTMY STEROWANIA LOTEM DRONA TYPU QUADPLANE

AUTOREFERAT

DYSCYPLINA NAUKOWA: AUTOMATYKA, ELEKTRONIKA,
ELEKTROTECHNIKA I TECHNOLOGIE KOSMICZNE
DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

mgr Michał Okulski

Instytut Automatyki i Informatyki Stosowanej
Wydział Elektroniki i Technik Informacyjnych
Politechnika Warszawska

Promotor: prof. dr hab. inż. Maciej Ławryńczuk

WARSZAWA 2023



Streszczenie

Opracowano całkowicie autorski projekt bezzałogowego statku powietrznego typu „quadplane”, o nazwie „Elka1Q”. Dron został skonstruowany, oprogramowany i uruchomiony. Przeprowadzono szereg eksperymentów: zarówno w kontrolowanych warunkach laboratoryjnych jak i podczas lotów.

Dron został zaprojektowany w oryginalny sposób: jest to połączenie rzadko spotykanego układu skrzydeł typu „tandem-wing”, czterech elektrycznych jednostek napędowych zoptymalizowanych do pionowego startu, lądowania i zawisu, oraz piątej elektrycznej jednostki napędowej zoptymalizowanej do rozpędzania drona w locie poziomym do wysokich prędkości przelotowych. Nietypowa konstrukcja powstała w celu zbadania możliwości zwiększenia zasięgu operacyjnego oraz zwiększenia prędkości przelotowej typowych dronów, przy jednoczesnym zachowaniu możliwości pionowego startu i lądowania oraz długotrwałego zawisu w powietrzu.

Zmodyfikowana konstrukcja w pewnych fazach lotu (start, lądowanie, zawis) powinna zachowywać się podobnie do klasycznych wielowirnikowych dronów (ang. *multi-rotor*, *multicopter*, *quadcopter*), natomiast w fazie lotu poziomego powinna zachowywać się podobnie do klasycznych samolotów. Jednak połączenie cech obydwu typów statków powietrznych w jednej konstrukcji spowodowało powstanie wielu dodatkowych zjawisk wymagających zbadania — w celu zoptymalizowania tworzonych algorytmów kontroli lotu.

Przeprowadzono modelowanie dynamiki drona w zawisie za pomocą metod klasycznych oraz całego szeregu modeli neuronowych, w tym także za pomocą autorskich typów rekurencyjnych modeli neuronowych. Zaimplementowano i przetestowano na pokładzie drona regulator predykcyjny (ang. *Generalized Predictive Control*, GPC), wykorzystujący różne modele (również neuronowe) uzyskane we wcześniejszych badaniach. Stworzono autorską modyfikację regulatora GPC: zaprojektowano i zaimplementowano algorytm „Trajectory Guessing”.

Przeprowadzono badanie jakości danych dostarczanych przez pokładową jednostkę IMU (ang. *Inertial Measurement Unit*). Zaprojektowano autorską modyfikację klasycznego algorytmu bazującego na filtrze Kalmana, dzięki której znacząco poprawiono dokładność i precyzję modułu IMU.

Finalnie zbadano właściwości drona podczas lotów poziomych z różnymi prędkościami, oraz przejścia pomiędzy różnymi fazami lotu. W trakcie eksperymentów zidentyfikowano i rozwiązano wiele trudności technicznych (związanych z konstrukcją mechaniczną) oraz problemów ze stabilnością lotu — zarówno dotyczących zagadnień aerodynamicznych jak i związanych z algorytmami regulacji i sterowania.

Słowa kluczowe: UAV, bezzałogowy statek powietrzny, dron, quadplane, tandem, sterowanie, identyfikacja, model neuronowy, IMU, GPC, MPC, regulator predykcyjny

Abstract

A novel unmanned aerial vehicle (UAV) design has been developed. The quad-plane drone (named 'Elka1Q') was built, programmed, and tested. Many experiments were carried out: in controlled laboratory conditions and actual flights.

The drone has an unusual design: it combines a rare tandem-wing, four electric drives optimised for vertical take-off, landing and hover, and a fifth electric drive optimised for accelerating to high cruise speed in horizontal flight. The non-standard design was developed to explore the possibility of extending the operational range and increasing the cruise speed of a small drone while retaining the ability for vertical take-off and landing as well as long-term hovering.

The modified design in some flight phases (take-off, landing, hovering) should behave similarly to a classic multi-rotor drone (*multicopter*, *quadcopter*). In contrast, it should behave similarly to a fixed-wing aircraft in the horizontal flight phase. However, combining the characteristics of both airframes in a single design introduces some other phenomena that need to be investigated — to optimise the flight control algorithms as much as possible.

Modelling of the dynamics of the drone in hover conditions was conducted using classical methods and a whole range of neural network models, including novel types of recursive neural models. A model predictive controller (MPC) was implemented and tested onboard, using various models (including the neural models) obtained in earlier studies. A novel modification of the Generalized Predictive Controller (GPC) was proposed: the 'Trajectory Guessing' algorithm was designed, implemented, and tested onboard.

A study of the quality of the data provided by the onboard IMU (Inertial Measurement Unit) was carried out. A novel modification of the classical algorithm based on the Kalman filter was proposed. The modification significantly improved the accuracy and precision of the IMU.

Ultimately, the properties of the drone during horizontal flight at various speeds, and transitions between different flight phases, were investigated. Some technical issues were identified and resolved. The problems were found during the flight experiments and were related to mechanical design and general flight stability (including aerodynamic and control system issues). The issues were investigated, and most of them were mitigated successfully.

Keywords: *UAV, Unmanned Aerial Vehicle, drone, quadplane, tandem, control, system identification, neural network model, IMU, GPC, MPC, Model Predictive Controller*

Spis treści

1. Wprowadzenie	5
2. Motywacja	6
3. Zakres pracy badawczej	7
4. Elka1Q — opis konstrukcji drona	9
4.1. Założenia projektu	11
4.2. Konstrukcja mechaniczna i układ aerodynamiczny	12
4.3. Zespoły napędowe	15
4.4. Elektronika i czujniki pokładowe	16
4.5. Architektura systemów sterowania	18
5. Precyzyjna i dokładna jednosta IMU zbudowana z niskobudżetowych sensorów	21
5.1. Motywacja	21
5.2. Modyfikacja algorytmu fuzji danych sensorów opartego o filtr Kalmana	21
6. Identyfikacja dynamiki drona za pomocą modeli neuronowych	23
6.1. Bezpieczne środowisko testowe	24
6.2. Modele neuronowe	26
6.3. Finalny model Feature-Sequence-to-Sequence	27
6.4. Transformacja klasycznych modeli liniowych do modeli neuronowych .	30
7. „Trajectory Guessing” — modyfikacja regulatora GPC w wewnętrznej pętli sterowania	31
7.1. Motywacja	31
7.2. Implementacja	31
8. Wyniki eksperymentów w locie	34
8.1. Napotkane problemy i zastosowane rozwiązania	34
9. Podsumowanie	36
A. Życiorys	38
Literatura	39

Spis rysunków


1.1	Popularne typy bezzałogowych statków powietrznych	5
4.1	Elka1Q — dron typu „Tandem-Wing Quadplane”	10
4.2	Elka1Q podczas testów w locie	11
4.3	Wizualizacja konstrukcji drona Elka1Q	12
4.4	Projekt konstrukcji drona Elka1Q — widok z góry	13
4.5	Projekt konstrukcji drona Elka1Q — widok z boku	13
4.6	Projekt szkieletu wewnętrznego	14
4.7	Wewnętrzna struktura konstrukcji kadłuba	14
4.8	Struktura wewnętrzna skrzydła	15
4.9	Diagram systemów elektronicznych drona Elka1Q	17
4.10	Struktura systemu sterowania w ArduPilot (Copter)	19
4.11	System stabilizacji orientacji w przestrzeni w ArduPilot (Copter) . . .	20
5.1	Zautomatyzowany gimbal	22
5.2	Poprawa dokładności IMU	23
6.1	Osie obrotów i siły występujące podczas sterowania	24
6.2	Bezpieczne środowisko testowe dla drona Elka1Q	25
6.3	Dane telemetryczne	25
6.4	Finalny (autorski) model neuronowy Feature-Sequence-to-Sequence	28
6.5	Wyniki predykcji modelu neuronowego fseq2seq	29
7.1	Wynik filtrowania danych z jednostki <i>IMU</i>	33
7.2	Wizualizacja koncepcji „Trajectory Guessing”	33
7.3	Porównanie jakości śledzenia trajektorii dla różnych regulatorów . . .	34
8.1	Widok z kamery pokładowej drona Elka1Q	35

Spis tabel

1	Oszacowanie osiągnięć drona Elka1Q	10
2	Zastosowane zespoły napędowe.	16

1. Wprowadzenie

Bezzałogowe statki powietrzne (ang. Unmanned Aerial Vehicles, UAV, potocznie: drony) zyskują coraz większą popularność na całym świecie [67]. Rynek usług związanych z dronami rozwija się niezwykle dynamicznie — niemalże wykładniczo. Dzieje się tak, ponieważ drony są z powodzeniem wykorzystywane w szerokiej gamie misji, zarówno wojskowych jak i cywilnych. Najważniejsze zastosowania cywilne obejmują: operacje poszukiwawczo-ratunkowe (ang. Search-and-Rescue, SAR) [65, 3, 2, 52], monitorowanie infrastruktury, inspekcję budowli [37], mapowanie terenu oraz fotogrametria [53], zastosowanie w branży filmowej (zdjęcia i filmy), rolnictwo precyzyjne, ochrona mienia i automatyczny nadzór, wykrywanie pożarów lasów, wsparcie taktyczne dla służb mundurowych (policja, straż graniczna, straż pożarna, straż miejska, straż ochrony kolei), rozrywka i sport (np. wyścigi dronów), transport towarów (paczek) [25], transport artykułów medycznych [55], walka ze skutkami pandemii COVID-19 [19, 34], zastosowania badawcze.



Rysunek 1.1: Popularne typy bezzałogowych statków powietrznych

2. Motywacja

Rodzaj konstrukcji bezzałogowego statku powietrznego jest najczęściej ściśle związany z misją, którą ma wykonywać. W związku z tym skonstruowano do tej pory wiele różnych typów dronów [64, 23] — najpopularniejsze z nich [14, 28, 7, 64, 10, 51, 39, 27, 35, 69, 64, 18, 30, 15, 21, 20, 43, 72, 74] przedstawione są na rys. 1.1.

Cechą wspólną większości misji wykonywanych przez drony, jest ograniczenie czasu jej trwania przez ograniczone zasoby energii dla zastosowanych układów napędowych (np. pojemność akumulatora lub zbiornika paliwa). Czas pracy układów napędowych z kolei determinuje zasięg operacyjny drona. W pewnym uproszczeniu, można przyjąć, że drony ze skrzydłami (podobne do klasycznych samolotów, np. rys. 1.1a oraz 1.1b) mają większy zasięg, ponieważ zużywają mniej energii podczas lotu poziomego. Nie są one jednak zdolne ani do zawisu w powietrzu, ani do pionowego startu i lądowania, co wyklucza możliwość ich zastosowania w pewnych klasach misji (np. zdalna inspekcja infrastruktury). Drony wielowirnikowe lub zbliżone do klasycznych helikopterów (np. rys. 1.1c – 1.1f) z kolei zużywają więcej energii podczas lotu poziomego, ale pozwalają na długotrwały zawis nad celem misji oraz mogą startować i lądować niemalże w dowolnym miejscu. Istnieją hybrydowe rozwiązania: samoloty z dołączonymi dodatkowymi zestawami silników i śmigieł umożliwiającymi pionowy start, lądowanie, oraz zawis (np. rys. 1.1g). Konstrukcje typu „quadplane” charakteryzują się jednak nieco gorszymi osiąganiami (w porównaniu do klasycznych samolotów), ze względu na masę oraz opór aerodynamiczny stawiany przez dodatkowe zespoły napędowe.

Rozważając cechy różnych typów dronów, zadałem następujące pytanie: *W jaki sposób znacząco zwiększyć zasięg niewielkiego drona, zachowując przy tym jego dużą zwrotność, zdolność do zawisu, pionowego startu i lądowania?* Przykładem wojskowego zastosowania dla drona spełniającego takie wymagania może być misja rozpoznawcza, którą można przeprowadzać z bezpieczniejszej odległości od frontu, wykorzystując przy tym możliwość manewrowania i zawisu blisko naturalnych przeszkód terenowych (np. drzew lub budynków). Cywilnym zastosowaniem z kolei może być przykład inspekcji linii i słupów energetycznych: konieczny jest długi lot wzdłuż zawieszonych kabli, z przerwami na inspekcję każdego słupa energetycznego (konieczny zawis).

Tezę pracy można zatem sformułować w następujących punktach:

1. W celu znaczącego zwiększenia zasięgu niewielkiego drona, zachowując przy tym jego dużą zwrotność, zdolność do zawisu, pionowego startu i lądowania, należy wykorzystać konstrukcję „quadplane”, która wykorzystuje 4 zespoły napędowe zoptymalizowane do zawisu oraz 5-ty zespół napędowy zoptymalizowany do lotu poziomego z dużą szybkością. Należy zastosować układ aerodynamiczny typu „tandem” ze względu na korzystne zlokalizowanie środka ciężkości oraz mini-

malizację liczby elementów konstrukcji — wsporniki czterech silników są w tym układzie jednocześnie skrzydłami.

2. Ze względu na znaczące różnice konstrukcyjne względem klasycznych dronów, konieczne jest przeprowadzenie dokładnej identyfikacji modelu dynamiki, a następnie porównanie skuteczności standardowych modeli liniowych oraz różnych typów modeli neuronowych. Najlepsze modele staną się podstawą dla zaprojektowanych algorytmów regulacji predykcyjnej.
3. W celu znacznego zwiększenia agresywności sterowania orientacją przestrzenną drona podczas lotu, należy zastosować opracowaną modyfikację regulatora predykcyjnego typu GPC.

Weryfikacja tej tezy stała się podstawą moich dalszych prac badawczych. Wizualizacja drona opisanego w tezie przedstawiona jest na rys. 1.1h.

Należy wspomnieć, że samoloty w układzie „tandem” są dość rzadkie [83, 33, 40], natomiast drony tego typu są jeszcze rzadsze — praktycznie nie występują w literaturze naukowej. Pojedyncze publikacje dotyczą jedynie dronów-samolotów lub dronów pionowego startu, z uchylnymi zespołami napędowymi [1, 21, 44] lub uchylnymi skrzydłami [43, 12]. **Zaproponowany przeze mnie typ drona jest innowacyjny i nie został do tej pory zbadany** — pomimo dołożenia wszelkich starań podczas przeglądu literatury, nie znalazłem żadnych publikacji opisujących taki rodzaj konstrukcji.

3. Zakres pracy badawczej

W toku studiów doktoranckich opracowałem całkowicie autorski projekt bezzałogowego statku powietrznego typu „quadplane”, o nazwie „Elka1Q”. Dron został skonstruowany, oprogramowany i uruchomiony. Przeprowadzono szereg eksperymentów: zarówno w kontrolowanych warunkach laboratoryjnych jak i podczas lotów.

Dron został zaprojektowany w oryginalny sposób: jest to połączenie rzadko spotykanego układu skrzydeł typu „tandem-wing”, czterech elektrycznych jednostek napędowych zoptymalizowanych do pionowego startu, lądowania i zawisu, oraz piątej elektrycznej jednostki napędowej zoptymalizowanej do rozpędzania drona w locie poziomym do wysokich prędkości przelotowych. Nietypowa konstrukcja powstała w celu zbadania możliwości zwiększenia zasięgu operacyjnego oraz zwiększenia prędkości przelotowej typowych dronów, przy jednoczesnym zachowaniu możliwości pionowego startu i lądowania oraz długotrwałego zawisu w powietrzu.

Zmodyfikowana konstrukcja w pewnych fazach lotu (start, lądowanie, zawis) powinna zachowywać się podobnie do klasycznych wielowirnikowych dronów (ang. *multi-rotor*, *multicopter*, *quadcopter*), natomiast w fazie lotu poziomego powinna zachowywać się podobnie do klasycznych samolotów. Jednak połączenie cech obydwu typów statków powietrznych w jednej konstrukcji spowodowało powstanie wielu do-

datkowych zjawisk wymagających zbadania — w celu zoptymalizowania tworzonych algorytmów kontroli lotu.

Przeprowadziłem modelowanie dynamiki drona w zawisie za pomocą metod klasycznych oraz całego szeregu modeli neuronowych, w tym także za pomocą autorskich typów rekurencyjnych modeli neuronowych. Zaimplementowałem i przetestowałem na pokładzie drona regulator predykcyjny (ang. *Generalized Predictive Control*, GPC), wykorzystujący różne modele (również neuronowe) uzyskane we wcześniejszych badaniach. Wysiłki związane z poprawą jakości i agresywności sterowania doprowadziły do stworzenia przeze mnie autorskiej modyfikacji regulatora GPC: zaprojektowałem i zaimplementowałem algorytm „Trajectory Guessing”.

Finalnie badałem właściwości drona podczas lotów poziomych z różnymi prędkościami, oraz przejścia pomiędzy różnymi fazami lotu. W trakcie eksperymentów w locie zidentyfikowałem i rozwiązałem wiele trudności natury technicznej (związanych z konstrukcją mechaniczną), problemów ze stabilnością lotu — zarówno dotyczących zagadnień aerodynamicznych jak i związanych ściśle z algorytmami regulacji i sterowania.

Podsumowując, mój **autorski wkład naukowy** obejmuje w szczególności następujące osiągnięcia:

1. Zaprojektowanie, skonstruowanie, oprogramowanie, regulacja, oblatanie i analiza osiągnięć drona Elka1Q — stworzonego w celu zbadania sposobu zwiększenia zasięgu bezzałogowego statku powietrznego zdolnego do pionowego startu i lądowania oraz wykonywania misji wymagających długotrwałego zawisu.
2. Poprawienie precyzji i dokładności jednostki IMU (ang. *Inertial Measurement Unit*), bazującej na niskobudżetowym i łatwo dostępnym akcelerometrze i żyroskopie, dzięki modyfikacji algorytmu fuzji danych w filtrze Kalmana.
3. Opracowanie nowego typu modelu neuronowego (Feature-Sequence-to-Sequence) — z powodzeniem zastosowanego do modelowania dynamiki drona.
4. Opracowanie metody wydajnej identyfikacji modelu w przestrzeni stanu oraz modelu w postaci równania różnicowego za pomocą sprowadzenia ich do równoważnych sieci neuronowych.
5. Modyfikacja regulatora predykcyjnego (ang. *Generalized Predictive Control*, GPC): algorytm „Trajectory Guessing” pozwalający na znaczne zwiększenie agresywności sterowania orientacją przestrzenną drona podczas lotu.
6. Przeprowadzona została analiza wydajności energetycznej (zużycia energii) podczas agresywnych manewrów dronem.

Wyniki swoich prac szczegółowo opisałem w następujących publikacjach:

1. Okulski M., Ławryńczuk M.: A small UAV optimized for efficient long-range and VTOL missions: An experimental tandem-wing quadplane drone, Applied

- Sciences, sekcja specjalna: Unmanned Aerial Vehicles, t. 12, praca 7059, 2022, **IF: 2.838, 100 pkt.**
2. Okulski M., Ławryńczuk M.: How much energy do we need to fly with greater agility? Energy consumption and performance of an attitude stabilization controller in a quadcopter drone: A modified MPC vs. PID , Energies, t. 15, praca 1380, 2022, **IF: 3.252, 140 pkt.**
 3. Okulski M., Ławryńczuk M.: A novel neural network model applied to modeling of a tandem-wing quadplane drone, IEEE Access, t. 9, s. 14159-14178, 2021, **IF: 3.476, 100 pkt.**
 4. Okulski M., Ławryńczuk M.: Identification of linear models of a tandem-wing quadplane drone: preliminary results, Advanced, Contemporary Control, Advances in Intelligent Systems and Computing t. 1196, red.: Bartoszewicz A., Kabziński J., Kacprzyk J., s. 219-228, Springer, Cham, 2020, **20 pkt.**
 5. Okulski M., Ławryńczuk M.: Development of a high-efficiency pitch/roll inertial measurement unit based on a low-cost accelerometer and gyroscope sensors, Proceedings of the 24th IEEE International Conference on Methods and Models in Automation and Robotics MMAR 2019, s. 657-662, Międzyzdroje, 2019, **20 pkt.**

W trakcie studiów doktoranckich zajmowałem się również robotyką. Wyniki prac opisałem w następujących publikacjach:

1. Okulski M., Ławryńczuk M.: A cascade PD controller for heavy self-balancing robot, Automation 2018, Advances in Intelligent Systems and Computing, t. 743, red.: Szewczyk R., Zieliński C., Kaliczyńska M., s. 183–192, Springer, Heidelberg, 2018, **20 pkt.**
2. Okulski M., Ławryńczuk M.: Development of a model predictive controller for an unstable heavy self-balancing robot, Proceedings of the 23th IEEE International Conference on Methods and Models in Automation and Robotics MMAR 2018, s. 503-508, Międzyzdroje, 2018, **20 pkt.**

Wyniki swoich prac prezentowałem na następujących konferencjach:

1. Krajowa Konferencja Automatyki KKA 2020, Łódź,
2. IEEE International Conference on Methods and Models in Automation and Robotics MMAR 2019, Międzyzdroje,
3. IEEE International Conference on Methods and Models in Automation and Robotics MMAR 2018, Międzyzdroje,
4. Automation 2018, Warszawa.

4. Elka1Q — opis konstrukcji drona

Wszystkie szczegóły konstrukcji drona Elka1Q, założenia projektowe, metodologia testów naziemnych i prób w locie oraz uzyskane wyniki zostały opisane w pu-

blikacji [48]. Wybrane osiągi zaprezentowane są w tabeli 1. W szczególności warto zwrócić uwagę na znacznie większą prędkość przelotową oraz znacznie większy zasięg w trybie samolotowym niż w trybie „Quadcopter”. Mimo optymalizacji konstrukcji pod kątem lotów z dużymi prędkościami, dron jest nadal zdolny do długotrwałego zawisu w powietrzu.



Rysunek 4.1: Elka1Q — dron typu „Tandem-Wing Quadplane”; zaprojektowany, zbudowany i przetestowany w toku studiów doktoranckich

Tabela 1: Oszacowanie osiągnięć drona Elka1Q; założono rozładowanie max. 90% pojemności akumulatora oraz 300 g ładunku (np. kamera wraz z komputerem).

Masa własna	2600 g
Założona masa startowa	2900 g (2600 g + 300 g ładunku)
Czas zawisu	ok. 20,4 min
Prędkość maksymalna	ok. 122–144 km/h¹ (w trybie samolotowym) 32–45 km/h (w trybie „Quadcopter”)
Maksymalny zasięg	ok. 25 km¹ (VTOL², tryb samolotowy) ok. 4,6 km (w trybie „Quadcopter”)
Prędkość przeciągnięcia (w trybie samolotowym)	ok. 40–50 km/h

¹ Wartości znacząco wyższe w porównaniu do typowych dronów wielowirnikowych

² Pionowy start i lądowanie, ang. *Vertical Take-off and Landing*



Rysunek 4.2: Elka1Q podczas testów w locie

4.1. Założenia projektu


Skonstruowano i zbadano dotychczas wiele różnych typów dronów — każdy przeznaczony do innego rodzaju zadań. Najpopularniejsze typy przedstawione zostały na rys. 1.1. Przykładowe zastosowania wskazanych na rys. 1.1 typów dronów zostały przeze mnie opisane w [48].

Większość misji wykonywanych przez drony zyskała by na efektywności, gdyby drony dysponowały większym zasięgiem. Mowa tu w szczególności o misjach związanych z zawisem nad odległym celem, takich jak inspekcja infrastruktury energetycznej w trudno dostępnych miejscach, patrolowanie odległych punktów wzdłuż obszarów chronionych lub strategicznie ważnych, a na zastosowaniach militarnych kończąc. Projekt Elka1Q powstał w celu zbadania sposobu istotnego zwiększenia zasięgu średniej wielkości drona, przy jednoczesnym zachowaniu zdolności do pionowego startu i lądowania (ang. *Vertical Take-off and Landing*, VTOL) oraz zdolności do długotrwałego zawisu nad odległym celem.

W celu zwiększenia zasięgu zaprojektowałem hybrydowego drona łączącego cechy wielowirnikowców (ang. *multirotors*, *multicopters*) z cechami samolotów (ang. *fixed-wing drones*). Szczegółowe założenia dot. wymiarów, masy, udźwigu itp. opisane zostały w [48].

4.2. Konstrukcja mechaniczna i układ aerodynamiczny

Pierwszy szkielet wewnętrzny drona Elka1Q wykonany został jako półotwarta kratownica frezowana CNC z laminowanych płyt z włókna węglowego. Już wstępne próby startu i zawisu wykazały jednak niedostateczną sztywność konstrukcji i podatność na ugięcia wokół osi podłużnej. W celu wyeliminowania tego problemu, cały kadłub został zaprojektowany od nowa (rys. 4.3, 4.4, 4.5) — jako konstrukcja skorupowa (rura PVC), wzmocniona dodatkowo znacznie prostszym szkieletem drewnianym (sklejka frezowana CNC). Szczegóły nowej konstrukcji widoczne są na rys. 4.6 oraz 4.7.




Rysunek 4.3: Wizualizacja konstrukcji drona Elka1Q

Skrzydła wykonane zostały z dwóch części (górna i dolna, frezowane CNC 3D) z drewna balsowego. Znakomitą sztywność zapewniały podwójne dźwigary z laminatu węglowego (o przekroju prostokątnym). Dodatkowo krawędź natarcia i krawędź spływu skrzydła zostały również wzmocnione niewielkimi listewkami z włókna węglowego, czyniąc je praktycznie niewrażliwymi na przypadkowe uszkodzenia mechaniczne.


Oryginalny projekt skrzydła zakładał maksymalizację prędkości przelotowej (140–150 km/h). W związku z tym wybrany został profil laminarny P-51D TIP (BL215) [82]. Ze względów bezpieczeństwa zdecydowałem jednak, aby na potrzeby niniejszych badań obniżyć planowaną prędkość przelotową — aby to osiągnąć konieczne było

zwiększenie grubości profilu skrzydła widoczne na rys. 4.8. Na całej długości krawędzi spływu tylnych skrzydeł zamontowałem sterolotki.


Układ aerodynamiczny typu „Tandem” zakłada położenie środka ciężkości niemalże pośrodku, pomiędzy skrzydłami. Dzięki temu wszystkie cztery silniki „Quadrocopterowe” są równomiernie obciążone podczas zawisu w powietrzu. Taki układ skrzydeł w dużym lotnictwie stosowany jest rzadko. W literaturze można znaleźć zarówno informacje na temat jego zalet (związanych ze stabilnością dynamiczną czy korzystną charakterystyką przeciągnięcia) jak i wręcz przeciwne twierdzenia, sugerujące możliwe trudności ze stabilnością podczas lotu. Szerszą dyskusję na ten temat, wraz z wykazem źródeł, opisałem w [48].



Rysunek 4.4: Projekt konstrukcji drona Elka1Q — widok z góry




Rysunek 4.5: Projekt konstrukcji drona Elka1Q — widok z boku



Rysunek 4.6: Projekt szkieletu wewnętrznego wraz z mocowaniem dźwigarów skrzydeł; widoczne również mocowanie tylnego zespołu napędowego (pchającego)



Rysunek 4.7: Dron Elka1Q — widoczna wewnętrzna struktura konstrukcji oraz skłupa kadłuba



Rysunek 4.8: Struktura wewnętrzna skrzydła — widoczne dźwigary węglowe, kanał na przewody elektryczne, oryginalny profil skrzydła (pełne drewno balsowe) oraz późniejszy, zmodyfikowany profil (dodatkowe listwy i górne poszycie balsowe)

4.3. Zespoły napędowe

Silnik elektryczny wraz z zamontowanym śmigłem tworzy tzw. *zespół napędowy*. W literaturze czasami stosuje się uproszczony opis odnoszący się jedynie do samych silników, np. „*Quadcopter*» to dron z czterema silnikami.” Należy jednak pamiętać, że dobór odpowiedniego śmigła oraz źródła zasilania mają ogromny wpływ na osiągi zastosowanego silnika oraz osiągi całego drona.

Elementem wyróżniającym drona Elka1Q na tle innych konstrukcji typu „quad-plane” są m.in. zastosowane w nim zespoły napędowe. Cztery główne, zamontowane na końcach skrzydeł, zostały zoptymalizowane specjalnie do generowania dużego ciągu statycznego (siły nośnej), koniecznej podczas pionowego startu, lądowania oraz zawisu w powietrzu. Piąty zespół napędowy natomiast został zoptymalizowany do generowania ciągu w bardzo dużym zakresie prędkości. Szczegółowe dane zastosowanych zespołów napędowych zostały wymienione w tabeli 2.

W pewnym uproszczeniu można przyjąć, że śmigła o dużej średnicy i małym skoku, zwykle obracają się z mniejszą prędkością, ale wymagają znacznie większego momentu obrotowego i generalnie generują większą siłę (ciąg statyczny) przy tej samej mocy wejściowej niż śmigła o mniejszej średnicy i większym skoku. Jednak niewielka prędkość obrotowa w połączeniu z małym skokiem śmigła, powoduje drastyczny spadek generowanego ciągu podczas poruszania się (nawet z niewielką prędkością) w kierunku zgodnym z wektorem ciągu. Odnosząc się do omawianego drona: jego cztery zespoły napędowe już przy niewielkiej mocy generują wystarczający ciąg statyczny aby umożliwić start i zawis drona (także z dodatkowym ładunkiem na pokładzie), ale nawet przy pełnej mocy nie byłyby w stanie rozpędzić go w pionie i uzyskać dużej prędkości wznoszenia. Podczas wznoszenia z pewną, niezbyt dużą,

prędkością, ciąg generowany przez te zespoły napędowe gwałtownie spada i zrównuje się z ciężarem drona.

Tabela 2: Zastosowane zespoły napędowe.

Silniki „Quadcopterowe”	4× T-Motor MN3110 KV470
Śmigła „Quadcopterowe”	4× T-Motor Carbon-Fibre (CF) 12 × 4
ESC ¹ „Quadcopterowe”	4× Hobbywing Micro 35A 3-6S BLHeli
Typ akumulatora	Li-Ion, 18 szt. Sony US18650VTC5
Konfiguracja akumulatora	6S3P
Pojemność akumulatora	7500 mAh
Napięcie akumulatora	21,6 V nominalnie, 18–25,2 V pełen zakres
Waga akumulatora	936 g
Silnik pchający	1× T-Motor F60 PRO II KV1750
Śmigło pchające	1× APC-E 5 × 5 (2-łopatowe) lub 1× HQProp Ethix S5 5 × 4 × 3 (3-łopatowe)
ESC silnika pchającego	1× Beatles 50 A
Waga wszystkich zespołów napędowych wraz z akumulatorem	ok. 1800 g


¹ Regulator obrotów, ang. *Electronic Speed Controller*, ESC

W przypadku piątego zespołu napędowego (ze śmigłem pchającym) mamy do czynienia z sytuacją odwrotną. Zastosowałem tam wysokoobrotowe śmigło o niedużej średnicy, ale relatywnie dużym skoku — czyli o stosunku średnicy (ang. *Diameter*) do skoku (ang. *Pitch*) $D/P \approx 1$. Taki zespół napędowy generuje niewielki ciąg statyczny (w porównaniu do mocy wejściowej), ale spadek generowanego ciągu wraz ze wzrostem prędkości lotu jest niewielki, zatem pozwala on rozpędzić drona do znacznej prędkości. Maksymalna prędkość przelotowa zostaje osiągnięta wtedy, gdy siła oporu aerodynamicznego jest na tyle znaczna, że niweluje siłę ciągu zespołu napędowego.

Konfiguracja wszystkich zespołów napędowych została zaplanowana i zoptymalizowana z pomocą oprogramowania eCalc [73] oraz MotoCalc [79]. Osiągi obliczone przez te programy bardzo dobrze pokrywają się z wynikami pomiarów przeprowadzonych podczas lotów eksperymentalnych.

4.4. Elektronika i czujniki pokładowe

Kompletny system integracji modułów elektronicznych i elektrycznych przedstawiony jest na rys. 4.9. Głównym elementem wszystkich systemów elektronicznych drona Elka1Q jest moduł kontrolera lotu Kakute F7 AIO firmy Holybro [77]. Moduł zawiera wydajny mikrokontroler STM32F745 pracujący z częstotliwością 216 MHz, jednostkę IMU (ang. *Inertial Measurement Unit*, która integruje 3-osiowy akcelero-
metr, 3-osiowy żyroskop i 3-osiowy magnetometr), barometr, woltomierz, ampero-



Rysunek 4.9: Diagram systemów elektronicznych drona Elka1Q

mierz oraz złącze dla karty micro SD. Moduł został przeprogramowany i działa pod kontrolą zmodyfikowanej wersji oprogramowania ArduPilot [71] (wariant Copter), zawierającej autorskie poprawki i implementacje, w szczególności: dodatkowe tryby lotu, tryb testowy, własny kontroler orientacji drona — zmodyfikowany regulator GPC bazujący na modelu neuronowym. Zdecydowałem się na wybór oprogramowania bazowego ArduPilot ze względu na licencję *Open Source* (z otwartym kodem źródłowym). Dodatkowym atutem jest fakt, że oprogramowanie zostało przetestowane do tej pory w setkach różnych dronów i robotów przez liczną i aktywnie działającą społeczność wspierającą projekt ArduPilot.

Dodatkowo, do modułu kontrolera lotu podłączone zostały zewnętrzne moduły: GPS z wbudowanym kompasem, laserowy czujnik wysokości (wykorzystywany do precyzyjnego, automatycznego lądowania), modelarski odbiornik RC 2.4 GHz, dwukierunkowy radiowy moduł komunikacyjny 433 MHz (do przesyłania danych telemetrycznych oraz odbierania komend ze stacji bazowej), pięć trójfazowych regulatorów obrotów (4 szt. dla silników „Quadrocopterowych” oraz 1 szt. dla silnika pchającego), dwa serwomechanizmy klasy micro (do napędu sterolotek), programowalne diody LED (do zewnętrznej sygnalizacji), kamerę video oraz dwie przetwornice DC/DC (do zasilania modułów, serwomechanizmów i kamery).

Zintegrowanie dużej liczby różnych modułów w ciasnej przestrzeni kadłuba drona wymagało zaprojektowania i wykonania dedykowanej płytki drukowanej zawierającej wszystkie złącza. Przy wykonywaniu okablowania należało zwrócić szczególną uwagę na ryzyko wystąpienia silnych zakłóceń powodowanych przez elementy dużej mocy (silniki, regulatory) oraz ryzyko uszkodzeń mechanicznych ze względu na silne wibracje zespołów napędowych.


4.5. Architektura systemów sterowania

Implementacja własnych bibliotek i modyfikacja oprogramowania ArduPilot jest wygodna oraz przejrzysta — wszystko dzięki bogatej dokumentacji i rozbudowanej społeczności osób aktywnie wspierającej projekt.

W uproszczeniu można stwierdzić, że całe sterowanie dronem opiera się na wyborze odpowiedniego trybu lotu, np. ręczne sterowanie zadaniem kątem przechyłu (tryb *Stabilize*) lub ręczne sterowanie prędkością poziomą drona z automatyczną stabilizacją przechyłów (tryb *Loiter*) albo misja całkowicie autonomiczna, włącznie z automatycznym startem i lądowaniem (tryb *Auto*). Następnie funkcje drona sterowane są przez kaskadowy kontroler: pętla wyższego rzędu steruje pozycją drona (wymagany jest odbiornik GPS) i wydaje instrukcje do pętli wewnętrznej, czyli kontrolera orientacji drona w przestrzeni. Ten kontroler musi pracować z wysoką częstotliwością (400 Hz), aby zapewnić stabilność, dokładność i odpowiednią szybkość manewrowania dronem podczas lotu. Domyślną implementacją jest regulator PID [69], [35] z ograniczeniem całkowania. W zależności od wybranego trybu lotu,

sygnał sterujący odbierany z modelarskiego nadajnika RC, po uprzednim filtrowaniu, wpływa na zewnętrzną lub wewnętrzną pętlę sterowania. Warto wspomnieć, że precyzja i dokładność danych z modułu IMU jest krytycznie ważna dla osiągnięć szybkiego kontrolera orientacji oraz idąc dalej, również dla kontrolera pozycji czyli w konsekwencji, dla osiągnięć całej misji. Ten sam mikrokontroler (w module Kakute F7 AIO) jest również odpowiedzialny za syntezę danych z IMU — orientacja w postaci kątów Eulera (lub kwaternionów) obliczana jest z częstotliwością 1 kHz za pomocą rozszerzonego filtra Kalmana. Oprócz wspomnianego filtra Kalmana, kaskadowych regulatorów i filtrowania sygnałów z odbiornika RC, główny mikrokontroler odpowiedzialny jest również za obsługę zewnętrznych sensorów (np. GPS, kompas, laserowy dalmierz), nadawanie danych telemetrycznych, odbieranie komend sterujących oraz logowanie danych na kartę SD (odpowiednik czarnej skrzynki w samolocie). To wszystko sprawia, że wszelkie dodatkowe funkcje należy implementować z dużą ostrożnością, aby nie zakłócić (lub spowolnić) krytycznych funkcji kontrolera lotu.


Schemat pętli sterowania w oprogramowaniu ArduPilot (Copter) przedstawiony jest na rys. 4.10 i 4.11.



Rysunek 4.10: Struktura implementacji systemu sterowania w oprogramowaniu ArduPilot (Copter); źródło: <https://ardupilot.org/dev/docs/apmcopter-code-overview.html> z dnia 01.05.2022, opublikowane na licencji CC BY-SA 3.0 license: <https://creativecommons.org/licenses/by-sa/3.0/legalcode> z dnia 01.05.2022

W ramach prac badawczych zastąpiłem domyślny wewnętrzny regulator PID własną (ulepszoną) implementacją regulatora predykcyjnego GPC (z horyzontem

ArduCopter V4.X STABILIZE Roll, Pitch & Yaw PID's



Rysunek 4.11: Struktura systemu stabilizacji orientacji w przestrzeni w oprogramowaniu ArduPilot (Copter); źródło: <https://ardupilot.org/dev/docs/apmcopter-programming-attitude-control-2.html> z dnia 01.05.2022, opublikowane na licencji CC BY-SA 3.0 license: <https://creativecommons.org/licenses/by-sa/3.0/legalcode> z dnia 01.05.2022

predykcji $N = 30$, co odpowiada 75 ms), opartego na liniowym modelu neuronowym. Dużym wyzwaniem okazała się wydajna implementacja tego regulatora — przy pracy z częstotliwością 400 Hz długość kroku to teoretycznie 2,5 ms, ale w związku z tym, że mikrokontroler pokładowy obsługuje jednocześnie mnóstwo dodatkowych urządzeń i zadań, w praktyce do dyspozycji pozostawało ok 1,5 ms. Moja implementacja została zoptymalizowana w taki sposób, że finalnie każda iteracja regulatora GPC zajmowała niecałą 1 ms.

5. Precyzyjna i dokładna jednostka IMU zbudowana z niskobudżetowych sensorów


5.1. Motywacja

W poprzednim rozdziale wspomniałem, że wysokiej klasy moduł IMU jest krytycznie ważny do uzyskania najwyższej jakości regulatora orientacji w przestrzeni. Na bazie moich wcześniejszych doświadczeń związanych z budową i regulacją dronów wielowirnikowych wiedziałem, że możliwe są dwie drogi: zastosować gotowy, znacznie droższy (i często również cięższy) moduł IMU albo bliżej przyjrzeć się dostępnym cenowo komponentom i algorytmom fuzji danych. Moja hipoteza brzmiała następująco: *dzięki ulepszonym algorytmom fuzji danych oraz dokładnej kalibracji sensorów możliwe jest znaczące poprawienie dokładności i precyzji modułu IMU zbudowanego z tanich żyroskopów i akcelerometrów.*


5.2. Modyfikacja algorytmu fuzji danych sensorów opartego o filtr Kalmana

Pierwszym krokiem, niezbędnym do zweryfikowania postawionej przeze mnie hipotezy, było zbudowanie odpowiedniego środowiska testowego. W ten sposób powstał automatyczny gimbal (rys. 5.1) wyposażony w serwomechanizmy oraz bezkontaktowe enkodery magnetyczne. Taka konstrukcja pozwalała wykonać szereg powtarzalnych testów modułu IMU poprzez wykonywanie sekwencji obrotów w trzech osiach, ze ściśle kontrolowaną prędkością i przyspieszeniem kątowym. Jednocześnie magnetyczne enkodery zapewniały precyzyjne i dokładne źródło odniesienia.

Elementy mechaniczne gimbała wykonane zostały w technologii CNC z blachy aluminiowej. Płytki PCB dla elementów sterujących i enkoderów zostały zaprojektowane i wykonane specjalnie na potrzeby tego urządzenia. Całe oprogramowanie uruchomione zostało na płycie ewaluacyjnej mikrokontrolera STM32F4.



Rysunek 5.1: Zautomatyzowany gimbal — zbudowany do kalibracji i testowania własnego modułu IMU




Rysunek 5.2: Znacząca poprawa dokładności IMU zbudowanego z tanich akcelerometrów i żyroskopów dzięki zastosowaniu autorskiej modyfikacji filtru Kalmana

Następnie zbadałem niedoskonałości zastosowanych sensorów (nieliniowości, dryft temperaturowy) w szerokim zakresie warunków pracy. Zaproponowałem modyfikację klasycznego filtra Kalmana, polegającą na nieliniowym przełączaniu się pomiędzy odczytami z osi X oraz Z , mając na uwadze zbadane wcześniej charakterystyki każdej z osi akcelerometru. W ten sposób znacząco poprawiła się rola odczytu z akcelerometru w fazie korekcyjnej (*a posteriori*) w mojej implementacji filtra Kalmana. Więcej informacji na temat zastosowanej modyfikacji oraz omówienie uzyskanych wyników (przykład widoczny na rys. 5.2) można znaleźć w mojej publikacji [45].

6. Identyfikacja dynamiki drona za pomocą modeli neuronowych

Podstawą dobrej regulacji jest dobra znajomość regulowanego obiektu. Naturalnym wyborem mającym na celu znaczące poprawienie szybkości i dokładności regulatora pozycji drona w czasie lotu, było zastąpienie klasycznego regulatora PID

regulatorem predycyjnym. W tym celu niezbędne było poprawne zidentyfikowanie modelu dynamiki przechyłów drona (rys. 6.1).



Rysunek 6.1: Osie obrotów i siły występujące podczas sterowania przechylem drona

W celu uproszczenia identyfikacji, wykazałem w publikacjach [46] i [49], że problem orientacji w 3 wymiarach można rozłożyć na 3 niezależne zadania sterowania: przechyłu dla osi *Roll* i *Pitch* oraz obrotu wokół osi *Yaw*. W szczególności, zagadnienia matematyczne dotyczące przechyłów wokół osi *Roll* i *Pitch* są identyczne, dlatego w dalszych rozważaniach posługiwałem się odniesiem do osi *Pitch*.


6.1. Bezpieczne środowisko testowe

Aby skutecznie przeprowadzić wiarygodną identyfikację modelu przechyłów drona Elka1Q niezbędne było skonstruowanie kontrolowanego, bezpiecznego środowiska testowego (rys. 6.2). Zbudowałem dedykowany uchwyt pozwalający na obracanie się drona jedynie wokół jednej osi (*Pitch*). Istotne było również zadbanie o możliwość regulacji uchwytu, w taki sposób, aby oś obrotu znajdowała się dokładnie w środku ciężkości drona. Ważne było również zminimalizowanie niepożądanych efektów związanych z wtórnym odbiciem od podłoża podmuchu powietrza generowanego przez pracujące śmigła. W tym celu uchwyt umieszczony został na wysokości ok. 1,5m

oraz w dolnej części zastosowałem proste płytowe kierownice strumieni powietrza (odchylające je na boki).



Rysunek 6.2: Bezpieczne środowisko testowe dla drona Elka1Q — uchwyt pozwalający na przechyły jedynie wokół osi *Pitch*



Rysunek 6.3: Dane telemetryczne, tj. sygnał sterujący oraz kąt przechyłu drona wokół osi *Pitch*, zebrane podczas eksperymentów w bezpiecznym środowisku testowym; widoczny podział na dane uczące oraz dane weryfikujące (wykorzystywane do tuningu hiperparametrów modeli); dodatkowo wykorzystywany był jeszcze osobny zbiór danych testowych (nie przedstawionych na powyższym rysunku)

Dane telemetryczne zebrane podczas podążania za zadaną trajektorią (wokół osi *Pitch*) posłużyły do identyfikacji modelu dynamiki drona (rys. 6.3). Warto wspomnieć, że późniejsze porównanie metod identyfikacji dla danych zebranych podczas rzeczywistych lotów z danymi zebranymi podczas prób na stanowisku testowym, były bardzo zbliżone. Dane zebrane podczas lotów niestety zawierały dużo fragmentów zaburzających identyfikację, np. ze względu na podmuchy wiatru lub efekt poduszki powietrznej (ang. *ground effect*). Ręczna analiza danych telemetrycznych wraz z dokumentacją video z lotów w celu usunięcia niepożądanych fragmentów była bardzo pracochłonna — eksperymenty z wykorzystaniem środowiska testowego były znacznie prostsze i wydajniejsze.

6.2. Modele neuronowe

Dane telemetryczne, które mogły zostać wykorzystane do identyfikacji modelu zawierały następujące rodzaje informacji: historię kąta przechyłu θ (w osi *Pitch*) oraz historię sygnału sterującego u_θ (również dla osi *Pitch*). Wszystkie dane dostępne były w postaci dyskretnych próbek (częstotliwość próbkowania wynosiła 400 Hz). W związku z tym, możliwe było również uzyskanie wartości kolejnych pochodnych w chwili k dla kąta przechyłu, stosując rekurencyjny wzór:

$$\begin{aligned}\omega_\theta(k) &= \dot{\theta}(k) &= \theta(k) - \theta(k-1), \\ \ddot{\theta}(k) &= \dot{\theta}(k) - \dot{\theta}(k-1), \\ &\vdots \\ \theta^{(a)}(k) &= \theta^{(a-1)}(k) - \theta^{(a-1)}(k-1),\end{aligned}\tag{6.1}$$

gdzie $\theta(k)$ to kąt przechyłu w chwili k , $\omega_\theta(k)$ to pierwsza pochodna kąta przechyłu, czyli prędkość kątowna, a $\ddot{\theta}(k)$ to druga pochodna kąta przechyłu, czyli przyspieszenie kątowe, itd.

Przyjąłem następującą, uogólnioną formę poszukiwanego modelu (w postaci sieci neuronowej):

$$\hat{\omega}_\theta = f(\mathbf{w}, \boldsymbol{\theta}, d\boldsymbol{\theta}, \mathbf{u}_\theta),\tag{6.2}$$

gdzie $\hat{\omega}_\theta$ jest n -elementowym wektorem przewidywanych prędkości kątowych, począwszy od chwili $k+1$:

$$\hat{\omega}_\theta = [\hat{\omega}_\theta(k+1), \hat{\omega}_\theta(k+2), \dots, \hat{\omega}_\theta(k+n)],\tag{6.3}$$

w szczególnym przypadku, gdy sieć została zaprojektowana do przewidywania tylko jednego kroku naprzód, czyli gdy $n = 1$, wektor $\hat{\omega}_\theta$ będzie składał się z jednego elementu:

dla $n = 1$:

$$\begin{aligned}\hat{\boldsymbol{\omega}}_{\boldsymbol{\theta}} &= [\hat{\omega}_{\boldsymbol{\theta}}(k+1)], \\ \hat{\omega}_{\boldsymbol{\theta}}(k+1) &= f(\mathbf{w}, \boldsymbol{\theta}, d\boldsymbol{\theta}, \mathbf{u}_{\boldsymbol{\theta}}).\end{aligned}\tag{6.4}$$

W powyższych wzorach f jest funkcją reprezentującą sieć neuronową, $\mathbf{w}$ jest wektorem wag (parametrów) sieci neuronowej, $\boldsymbol{\theta}$ jest a -elementowym wektorem przeszłych kątów przechyłu począwszy od chwili k :

$$\boldsymbol{\theta} = [\theta(k), \theta(k-1), \dots, \theta(k-a)],\tag{6.5}$$

$d\boldsymbol{\theta}$ jest d -elementowym wektorem kolejnych pochodnych kąta przechyłu (prędkość, przyspieszenie, zryw, itd.), w chwili k :

$$d\boldsymbol{\theta} = [\dot{\theta}(k), \ddot{\theta}(k), \theta^{(3)}(k), \dots, \theta^{(d)}(k)],\tag{6.6}$$

oraz $\mathbf{u}_{\boldsymbol{\theta}}$ jest b -elementowym wektorem przeszłych wartości sygnału sterującego, począwszy od chwili k :


$$\mathbf{u}_{\boldsymbol{\theta}} = [u_{\boldsymbol{\theta}}(k), u_{\boldsymbol{\theta}}(k-1), \dots, u_{\boldsymbol{\theta}}(k-b)].\tag{6.7}$$

W publikacjach [46] i [49] opisałem całą gamę modeli neuronowych zastosowanych do identyfikacji dynamiki drona Elka1Q, m.in. sieci gęste (ang. *Fully-Connected* lub *Dense*), sieci rekurencyjne: klasyczne, LSTM, GRU, sieci rekursywne oraz zrównoleżone sieci gęste.


6.3. Finalny model Feature-Sequence-to-Sequence

W wyniku badania różnych typów i struktur modeli neuronowych (w sumie przetestowałem setki konfiguracji) zauważyłem, że modele oparte o neuronowe sieci rekurencyjne uzyskiwały obiecujące wyniki przewidywania, także przy dłuższych horyzontach predykcji. Sieci rekurencyjne posiadają stan wewnętrzny w postaci jednej, lub dwóch wartości dla każdego neuronu — w zależności od zastosowanego typu neuronów (np. *Vanilla RNN*, *LSTM*, *GRU*). W związku z tym, powstaje problem inicjalizacji stanu wewnętrznego sieci. Intuicja podpowiada powiązanie stanu wewnętrznego sieci z rzeczywistym (zmierzonym) stanem modelowanego obiektu, czyli pozycją drona.

Taki tok rozumowania był podstawą do stworzenia przeze mnie autorskiego typu rekurencyjnego modelu neuronowego, inicjalizowanego zmierzonym stanem obiektu. Następnie model rekurencyjny przetwarza wejściową sekwencję sygnału sterującego w wyjściową sekwencję przewidywanych stanów symulowanego obiektu. Stąd zaproponowana przez mnie nazwa modelu: **Feature-Sequence-to-Sequence**.



Rysunek 6.4: Finalny (autorski) rekurencyjny model neuronowy **Feature-Sequence-to-Sequence**, w skrócie: **fseq2seq**



Rysunek 6.5: Wyniki predykcji modelu neuronowego **fseq2seq** względem danych testowych

W celu zmniejszenia liczby parametrów modelu (liczby wag), wprowadziłem dodatkową strukturę, nazwaną **Pseudo-Attention Layer**. Dzięki niej, model redukuje ilość wejściowych sygnałów sterujących wykorzystywanych do finalnej predykcji w części rekurencyjnej.

Cała struktura modelu **fseq2seq** (skrót od: Feature-Sequence-to-Sequence) przedstawiona jest na rys. 6.4. Model zasilany jest na początku (jednorazowo) danymi pochodzącymi z obserwacji stanu drona, czyli kątem przechyłu oraz kilkoma wartościami pochodnych kąta przechyłu w chwili k (zgodnie ze wzorami 6.1 oraz 6.2). Sieć gęsta transformuje (nieliniowo) zmierzony stan drona, na wartości inicjujące stany wewnętrzne neuronów rekurencyjnych. Następnie w kolejnych krokach, na wejścia warstwy Pseudo-Attention Layer, podawane są historyczne wartości sygnału sterującego $\mathbf{u}_\theta$ (w postaci przesuwanego okna o ustalonej długości). Sygnały te są ważone i sumowane do pojedynczej wartości, która stanowi sygnał wejściowy do części rekurencyjnej modelu. Wyjścia neuronów rekurencyjnych są następnie ważone

i sumowane do pojedynczej wartości, będącej sygnałem wyjściowym modelu — czyli przewidywaną wartością $\hat{\omega}_\theta(k+t)$, dla $t = 1 \dots n$.

Przykładowe wyniki predykcji modelu **fseq2seq** względem danych telemetrycznych przedstawione są na rys. 6.5.

6.4. Transformacja klasycznych modeli liniowych do modeli neuronowych

W toku badań nad modelami neuronowymi sformułowałem wzory transformujące klasyczne modele liniowe, na matematycznie równoważne modele neuronowe:

1. dyskretny model w postaci równania różnicowego opisanego ogólnym wzorem:

$$\begin{aligned}\hat{\omega}_\theta(k+1) = & a_1\theta(k) + a_2\theta(k-1) + \dots + a_n\theta(k-n+1) + \\ & + b_1u_\theta(k) + b_2u_\theta(k-1) + \dots + b_nu_\theta(k-n+1)\end{aligned}\quad (6.8)$$

2. dyskretny model w przestrzeni stanu, opisany ogólnym wzorem:

$$\begin{aligned}X(k+1) &= A \times X(k) + B \times \mathbf{u}_\theta \\ \hat{\omega}_\theta(k+1) &= C \times X(k+1)\end{aligned}\quad (6.9)$$

Neuronowym odpowiednikiem dyskretnego modelu opisanego równaniem różnicowym 6.8 jest głęboki model rekursywny, z pojedynczym neuronem liniowym w każdej warstwie (wszystkie neurony współdzielały te same wagi oraz nie posiadają tzw. biasu).

Z kolei odpowiednikiem modelu w przestrzeni stanu (równanie 6.9) jest sieć rekurencyjna z liniowymi neuronami (pozbawionymi biasu) oraz pojedynczy neuron liniowy ważący i sumujący wyjścia neuronów rekurencyjnych (neuron wyjściowy — również pozbawiony biasu). Ilość neuronów rekurencyjnych odpowiada dokładnie ilości elementów w wektorze X . Co więcej, stany wewnętrzne neuronów rekurencyjnych są w istocie dokładnie elementami stanu modelu (wektora X).

Szczegóły transformacji wymienionych wyżej modeli, wraz z omówieniem uzyskanych wyników predykcji, opisałem w publikacji [49].

Istotą transformacji klasycznych modeli, do modeli neuronowych, jest możliwość wykorzystania współczesnych bibliotek dedykowanych do wydajnego trenowania sieci neuronowych (np. *TensorFlow* [84]). Tego typu biblioteki pozwalają na wykorzystanie pełnej mocy dedykowanych jednostek obliczeniowych takich jak *GPU* oraz *TPU*, w celu znaczącego przyspieszenia procesu trenowania sieci neuronowych — czyli w tym przypadku — **znaczącego przyspieszenia identyfikacji modeli**.

7. „Trajectory Guessing” — modyfikacja regulatora GPC w wewnętrznej pętli sterowania

Opisane powyżej prace, związane z identyfikacją modelu dynamiki drona Elka1Q, zakończyły się stworzeniem kilku obiecujących modeli — zarówno nieliniowych jak i liniowych. Modele liniowe tylko nieznacznie ustępowały (pod względem jakości predykcji) modelom nieliniowym. Dodatkowo, modele liniowe cechuje znacznie niższa złożoność obliczeniowa, a także możliwość bezpośredniego zastosowania w regulatorach predykcyjnych (np. GPC). Mając na uwadze te cechy, postanowiłem zbadać możliwość implementacji regulatora predykcyjnego na pokładzie drona Elka1Q.

7.1. Motywacja

Standardowe regulatory PID zastosowane w wewnętrznej (szybkiej) pętli sterowania, czyli odpowiedzialnej bezpośrednio za utrzymanie pożądanej pozycji (orientacji) drona w przestrzeni, co prawda pozwalają na przeprowadzenie wstępnych prób w locie, jednak ze względu na niestandardową konstrukcję drona (dwie pary skrzydeł), jakość regulacji nie jest zadowalająca. W związku z tym postawiłem następujące pytanie: *czy regulator predykcyjny, bazujący na zidentyfikowanym wcześniej liniowym modelu neuronowym, znacząco poprawi jakość sterowania orientacją drona?* Wstępne wyniki testów przeprowadzonych w bezpiecznym środowisku testowym (opisanym powyżej) wykazały, że zaimplementowany przeze mnie regulator GPC bazujący na jednym z liniowych modeli neuronowych działa albo zbyt wolno, albo zbyt blisko granicy stabilności, powodując groźne wibracje. Problemy związane z dopasowaniem parametrów regulatora wynikały prawdopodobnie z niedoskonałości modelowania. To skłoniło mnie do **poszukiwania innych metod zwiększenia agresywności regulatora GPC**, przy jednoczesnym zastosowaniu najlepszych znanych wartości parametrów regulatora (horyzont predykcji N , horyzont sterowania N_u , parametr λ).

7.2. Implementacja

Regulator GPC został zaimplementowany przeze mnie bezpośrednio w języku C++, jako zamiennik standardowego regulatora `AC_AttitudeControl_Multi` z oprogramowania ArduPilot (Copter) [71]. Jak wspominałem w rozdziale 4.4, dużym wyzwaniem okazała się wydajna implementacja regulatora predykcyjnego, który miał pracować z częstotliwością 400 Hz, a w praktyce każde wywołanie powinno wykonać się w czasie nie dłuższym niż ok. 1,5 ms. Zastosowałem klasyczną postać analitycznego regulatora GPC opisanego wzorem macierzowym:

$$\Delta U(k) = K [Y_t(k+1) - Y_0(k+1)], \quad (7.1)$$

który w zapisie rozwiniętym wygląda następująco:

$$\begin{aligned}
\Delta U(k+1) &= \begin{bmatrix} \Delta u(k+1|k) \\ \Delta u(k+2|k) \\ \vdots \\ \Delta u(k+N_u+1|k) \end{bmatrix}_{N_u \times 1} = \\
&= K_{N_u \times N} \left(\begin{bmatrix} y_t(k+1|k) \\ y_t(k+2|k) \\ \vdots \\ y_t(k+N+1|k) \end{bmatrix}_{N \times 1} - \begin{bmatrix} y_0(k+1|k) + d(k) \\ y_0(k+2|k) + d(k) \\ \vdots \\ y_0(k+N+1|k) + d(k) \end{bmatrix}_{N \times 1} \right), \tag{7.2}
\end{aligned}$$

gdzie macierz K obliczana jest tylko raz (w fazie inicjalizacji regulatora), na podstawie modelu liniowego, y_t to kolejne wartości trajektorii zadanej (docelowej), y_0 to elementy trajektorii swobodnej, zależnej wyłącznie od zastosowanego modelu liniowego i przeszłych sygnałów sterujących u_θ ; $d(k)$ to błąd modelowania — różnica pomiędzy pomiarem stanu w chwili k , a predykcją stanu według modelu liniowego dla chwili k .


Jak widać we wzorze 7.2, duży wpływ na czas obliczeń każdej iteracji regulatora ma zastosowany horyzont sterowania N_u , ponieważ wpływa on bezpośrednio na rozmiar macierzy K , a więc również na finalną ilość mnożeń liczb zmiennoprzecinkowych. Największy wpływ jednak ma zastosowany horyzont predykcji N , ponieważ decyduje on o ilości obliczeń związanych z zastosowanym modelem liniowym.

Warto wspomnieć, że znaczącą poprawę stabilności regulatora, zaobserwowałem po zastosowaniu dodatkowego filtrowania danych z jednostki *IMU* (rys. 7.1). Parametry filtrowania należało dobrać tak, aby nie wprowadzać znaczącego dodatkowego opóźnienia do całego układu regulacji.


Finalnie, przy zastosowaniu horyzontu predykcji $N = 30$ oraz horyzontu sterowania $N_u = 2$ uzyskałem najlepszą charakterystykę pracy regulatora (podczas rzeczywistych eksperymentów z dronem), a czas obliczania sterowania przez regulator mieścił się nieco poniżej 1 ms.

Znaczący wpływ na skuteczność sterowania w regulatorze predykcyjnym ma trajektoria zadana, co widać we wzorze 7.1 oraz 7.2. Dron latający w rzeczywistym środowisku musi na bieżąco korygować swoją orientację i położenie — w związku z tym, zwykle trajektoria zadana nie jest znana lub znane jest zaledwie kilka przyszłych wartości naprzód. Z drugiej strony jednak, latający dron jest obiektem fizycznym o pewnej masie, bezwładności i znanej (skończonej) mocy zespołów napędowych. Oznacza to, że faktycznie **możliwe jest częściowe przewidywanie trajektorii zadanej**, ze względu na konieczność zachowania płynności manewrów oraz cechy fizyczne drona. W związku z tym zaproponowałem algorytm „Trajectory Gues-


„sing” polegający na wykorzystaniu prędkości i przyspieszenia kątownego trajektorii zadanej w chwili k do przewidywania kolejnych (przyszłych) wartości trajektorii zadanej. Przykład zastosowania algorytmu pokazany widać na rys. 7.2. Szczegóły algorytmu, zastosowanych ograniczeń, współczynników oraz szczegóły zastosowanego filtrowania opisałem w publikacji [47]. Na rys. 7.3 widać porównanie wyników dla regulatorów: PID, standardowego GPC oraz GPC z algorytmem „Trajectory Guessing”.



Rysunek 7.1: Wynik filtrowania danych z jednostki *IMU*; implementacja na pokładzie drona Elka1Q



Rysunek 7.2: Wizualizacja koncepcji „Trajectory Guessing” — przewidywania trajektorii zadanej w oparciu o pierwszą i drugą pochodną trajektorii zadanej w chwili k



Rysunek 7.3: Porównanie jakości śledzenia trajektorii przez drona Elka1Q dla różnych regulatorów zaimplementowanych na pokładzie: PID, standardowego GPC oraz GPC z algorytmem „Trajectory Guessing”

8. Wyniki eksperymentów w locie

Loty eksperymentalne podzielone zostały na dwie fazy:

1. testy wszystkich systemów pokładowych takich jak: regulator orientacji, regulator wysokości, regulator pozycji, odbiornik GPS, laserowy czujnik wysokości, kontroler automatycznego nawigowania, kontroler automatycznego lądowania, podstawowe manewrowanie w zawisie;
2. rozpędzanie drona w locie poziomym za pomocą piątego zespołu napędowego (ze śmigłem pchającym), przejście do fazy lotu poziomego na skrzydłach (cztery silniki „Quadrocopterowe” całkowicie wyłączone), powrót do zawisu i lądowanie.

Pierwsza część lotów odbyła się bez większych problemów. Drugi etap wiązał się ze znacznie większymi wyzwaniem, ponieważ wymagał rozpędzenia drona do dużych prędkości (powyżej prędkości przeciągnięcia, czyli ok. 50 km/h).

8.1. Napotkane problemy i zastosowane rozwiązania

Jak wspomniałem w rozdziale 4.2, na bardzo wczesnym etapie zidentyfikowałem problem związany z niedostateczną sztywnością kadłuba — podczas lotu dochodziło do skręcania całej konstrukcji wokół osi podłużnej. Ten problem został wyeliminowany.

wany przez całkowite przeprojektowanie konstrukcji kadłuba, włącznie z zastosowaniem zupełnie innych materiałów.



Rysunek 8.1: Widok z kamery pokładowej drona Elka1Q podczas lotów eksperymentalnych z dużą prędkością; wysokość ok. 55 m, prędkość ok. 100 km/h

Poważne problemy zostały zaobserwowane podczas pierwszych prób przejścia z trybu VTOL, do trybu w pełni „samolotowego”, czyli całkowitego wyłączenia czterech silników „Quadrocopterowych”. Pierwsze próby skutkowały gwałtownym nurkowaniem (pochyleniem drona w kierunku ziemi). Jedną z takich prób zakończyła się katastrofą — dron uderzył w ziemię w sposób niekontrolowany. Szczegółowa analiza danych telemetrycznych oraz nagrań video z chwili katastrofy sugerowała problem z wyważeniem drona. Układu aerodynamicznego typu „Tandem” jest nietypowy i (w zależności od interpretacji) można uzyskać różne wyniki optymalnego położenia środka ciężkości. Postanowiłem zastosować bardziej konserwatywne położenie środka ciężkości (z tzw. większym zapasem stabilności), przesunięte znacznie bardziej w kierunku przedniego skrzydła. Konstrukcja mechaniczna drona okazała się wyjątkowo solidna i mimo niekontrolowanego upadku z wysokości kilkunastu metrów, skala uszkodzeń była niewielka, więc dron został szybko naprawiony i przygotowany do następnych lotów.

Korekta położenia środka ciężkości przyniosła pożądane rezultaty — udało się przeprowadzić eksperymenty we wszystkich fazach lotu. Ze względów bezpieczeństwa jednak, nie zdecydowałem się na przeprowadzenie testu prędkości maksymalnej w locie poziomym. Finalnie dron rozpędził się do prędkości ok. 105 km/h, pobierając przy tym ok. 450 W mocy ciągłej — niemalże dokładnie tyle samo, ile wymaga do samego zawisu, korzystając z czterech silników „Quadrocopterowych”. Warto dodać, że co do zasady, wielowirnikowce zużywają znacznie więcej energii podczas lotu poziomego

niż podczas zawisu (ze względu na kierunek i wymaganą wartość wektorów ciągu zespołów napędowych). Bez piątego zespołu napędowego, zoptymalizowanego do lotów poziomych z dużymi prędkościami, dron nie byłby w stanie rozpędzić się nawet do połowy uzyskanej prędkości, korzystając wyłącznie z trybu wielowirnikowego.

Dalsze eksperymenty wykazały, że wraz ze wzrostem prędkości w locie poziomym, kumulujące się niepożądane efekty aerodynamiczne, utrudniają stabilną pracę regulatora orientacji. W danych telemetrycznych widoczne były narastające wibracje, a w konsekwencji oscylacje wokół osi *Pitch*. Podczas kilku lotów doszło do krótkotrwałej utraty stabilności. Podczas zmniejszania prędkości lotu, dron odzyskiwał stabilność. Jeden z eksperymentów zakończył się niestety kolejną katastrofą — podczas lotu z dużą prędkością doszło do gwałtownej utraty stabilności i dron uderzył w ziemię, lecąc niemal pionowo w dół z wysokości ok. 50 m. Analiza danych telemetrycznych i materiału video wykazała, że regulator zadziałał poprawnie, ale miał zbyt mało czasu na powrót do pełnej stabilności. Prawdopodobnie zwiększenie powierzchni sterolotek mogłoby pozytywnie wpłynąć na manewrowanie dronem w krytycznych sytuacjach i mogłoby uchronić go przed katastrofą.

9. Podsumowanie

W toku studiów doktoranckich przeprowadziłem szereg badań dotyczących konstrukcji, identyfikacji modelu oraz regulacji drona Elka1Q autorskiego projektu, w niestandardowym układzie „Tandem-Wing Quadplane”.

Finalnie skonstruowałem, oprogramowałem, zaprojektowałem algorytm regulacji i oblatywałem drona Elka1Q oraz przeprowadziłem wszystkie zaplanowane eksperymenty, włącznie z lotami testowymi z dużymi prędkościami. Potwierdziłem w ten sposób swoją tezę postawioną w rozdziale 2. Nietypowa konstrukcja typu „Tandem-Wing Quadplane” wraz ze starannie zaprojektowanymi i zoptymalizowanymi pięcioma układami napędowymi spełniła wszystkie założenia projektowe dotyczące możliwości pionowego startu, lądowania i zawisu, znacznie zwiększonego zasięgu operacyjnego, przy jednoczesnym zachowaniu kompaktowych rozmiarów oraz dużej zwrotności podczas lotu.

Uzyskanie dużej zwrotności drona w locie wymagało dogłębnej analizy istniejących algorytmów sterowania. Specjalnie w tym celu przeprowadziłem setki procesów identyfikacji modelu dynamiki drona. Testowałem zarówno klasyczne modele liniowe jak i różne modele neuronowe (włącznie z wieloma rzadkimi architekturami). Finalnie, zaprojektowany przeze mnie nowy typ modelu neuronowego osiągnął najlepsze wyniki. Następnie zaimplementowałem na pokładzie drona regulator predykcyjny (GPC) bazujący na najlepszych uzyskanych przez mnie modelach. Dalsza poprawa agresywności (zwrotności) wymagała modyfikacji samego algorytmu regulatora — w tym celu zaprojektowałem autorską modyfikację „Trajectory Guessing”. Wszystkie

modyfikacje zostały zaimplementowane i przetestowane na stacjonarnym środowisku testowym oraz podczas lotów eksperymentalnych.

W trakcie prac badawczych napotkałem wiele ciekawych zagadnień i problemów natury technicznej, teoretycznej oraz programistycznej. Zaproponowane przeze mnie rozwiązywania tych problemów przyczyniły się do wypracowania autorskiego wkładu naukowego (opisanego w rozdziale 3), w szczególności: stworzenie nowatorskiego typu rekurencyjnego modelu neuronowego, zaprojektowanie autorskiej modyfikacji „Trajectory Guessing” dla regulatora predykcyjnego GPC oraz autorska modyfikacja algorytmu fuzji danych bazującego na Filtrze Kalmana. Dodatkowo wszystkie nowatorskie rozwiązania zostały przeze mnie zaimplementowane i przetestowane z wykorzystaniem rzeczywistego sprzętu (komputer pokładowy drona oraz komputer jednostki IMU).

Propozycje przyszłych prac badawczych — uzupełnienie zebranych dotychczas doświadczeń oraz poszukiwanie efektywniejszego rozwiązania napotkanych problemów technicznych:

1. Rozwiązanie problemu utraty stabilności wraz ze wzrostem prędkości.
2. Modyfikacji układu skrzydeł w celu korzystniejszego położenia środka ciężkości.
3. Optymalizacja powierzchni sterowych — większe sterolotki, być może zlokalizowane również na przednim skrzydle, lub wyłącznie na przednim skrzydle.
4. Optymalizacja procedury lądowania — zbadanie efektywnych trajektorii opadania, z wykorzystaniem skrzydeł drona.

Krótki film (1 min 18 s) prezentujący osiągnięcia projektu Elka1Q dostępny jest pod adresem: <https://youtu.be/2cdPLeVac24> (tytuł: *Elka1Q UAV Project Overview*).

A. Życiorys



Michał Okulski Urodziłem się 27 listopada 1985 r. w Bydgoszczy. Szkołę podstawową oraz liceum ogólnokształcące ukończyłem w Chodzieży (woj. wielkopolskie). W 2004 r. rozpocząłem jednolite, magisterskie studia na Uniwersytecie im. Adama Mickiewicza w Poznaniu, na wydziale Matematyki i Informatyki, na kierunku: Informatyka, specjalność: Inżynieria Oprogramowania. Pracę magisterską pt. „*Zastosowanie sterowników rozmytych do automatycznego pilotażu drona*” obroniłem 14.07.2009 r. W 2017 r. rozpocząłem studia doktoranckie na Politechnice Warszawskiej, na Wydziale Elektroniki i Technik Informacyjnych, pod opieką prof. dra hab. inż. Macieja Ławryńczuka. W ramach studiów doktoranckich pracuję nad projektem autorskiego drona Elka1Q opisanego w cyklu artykułów pod wspólnym tytułem „*Zaawansowane modelowanie oraz algorytmy sterowania lotem drona typu «quadplane»*” (ang. „*Advanced modelling and flight control algorithms of a Quadplane drone*”). W latach 2007-2019 r. zawodowo zajmowałem się głównie programowaniem wysokopoziomowym, pracując dla różnych firm i korporacji z branży IT, m.in. Microsoft Corp., SeaChange Intl. W 2015 r. współtworzyłem projekt *rapidradio* sfinansowany na platformie *Kickstarter* i zakończony (z sukcesem) wyprodukowaniem ponad 600 modułów radiowych IoT różnego typu dla komputera RaspberryPi. W latach 2018-2019 pracowałem nad modulem stabilizacji oraz transmisji obrazu z pokładu drona produkowanego przez firmę MSP InnTech sp. z o.o. Od 2019 r. zajmuję się zarządzaniem projektami oraz zespołami badawczo-rozwojowymi w dziedzinie Artificial Intelligence / Machine Learning w korporacji Pearson plc.

Moja praca naukowa skoncentrowana jest głównie wokół bezzałogowych statków powietrznych (ang. *UAV*), ponieważ tematyka ta łączy wszystkie obszary moich zainteresowań, tj. programowanie, sterowanie, sztuczną inteligencję, elektronikę, mechanikę oraz latające modele zdalnie sterowane.

Literatura

- [1] J. Alba-Maestre, K. Prud'homme van Reine, T. Sinnige, and S. G. Castro. Preliminary propulsion and power system design of a tandem-wing long-range evtol aircraft. *Applied Sciences*, 11(23):11083, 2021.
- [2] M. Alicandro, D. Dominici, and V. Massimini. Surveys with uav photogrammetry: case studies in l'aquila during the post-earthquake scenario. In *EGU General Assembly Conference Abstracts*, page 14987, 2015.
- [3] M. Aljehani and M. Inoue. Performance Evaluation of Multi-UAV System in Post-Disaster Application: Validated by HITL Simulator. *IEEE Access*, 7:64386–64400, 2019.
- [4] G. Andria, A. Di Nisio, A. Lanzolla, M. Spadevecchia, G. Pascazio, F. Antonacci, and G. Sorrentino. Design and performance evaluation of drone propellers. In *2018 5th IEEE International Workshop on Metrology for AeroSpace (MetroAeroSpace)*, pages 407–412. IEEE, 2018.
- [5] S. Andropov, A. Guirik, M. Budko, M. Budko, and A. Bobtsov. Synthesis of artificial network based flight controller using genetic algorithms. In *2018 10th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)*, pages 1–5. IEEE, 2018.
- [6] K. J. Åström and R. M. Murray. *Feedback systems*. Princeton university press, 2010.
- [7] R. Austin. *Unmanned aircraft systems: UAVS design, development and deployment*. John Wiley & Sons, 2011.
- [8] B. Brinkworth. On the aerodynamics of the miles libellula tandem-wing aircraft concept, 1941–1947. *Journal of Aeronautical History Paper No*, page 02, 2016.
- [9] M. Budinger, A. Reyssset, A. Ochotorena, and S. Delbecq. Scaling laws and similarity models for the preliminary design of multicopter drones. *Aerospace Science and Technology*, 98:105658, 2020.
- [10] G. Cai, B. M. Chen, K. Peng, M. Dong, and T. H. Lee. Modeling and control system design for a uav helicopter. In *2006 14th Mediterranean Conference on Control and Automation*, pages 1–6, 2006.
- [11] E. F. Camacho and C. Bordons. *Model Predictive Control*. Springer, London, 1999.
- [12] E. Çetinsoy, S. Dikyar, C. Hanger, K. Oner, E. Sirimoglu, M. Unel, and M. Aksit. Design and construction of a novel quad tilt-wing uav. *Mechatronics*, 22(6):723–745, 2012.
- [13] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.
- [14] P.-H. Chung, D.-M. Ma, and J.-K. Shiau. Design, manufacturing, and flight testing of an experimental flying wing uav. *Applied Sciences*, 9(15):3043, 2019.
- [15] A. Dzul, T. Hamel, and R. Lozano. Modeling and nonlinear control for a coaxial helicopter. In *IEEE International Conference on Systems, Man and Cybernetics*, volume 6, pages 6–pp. IEEE, 2002.
- [16] E. Ebeid, M. Skriver, and J. Jin. A survey on open-source flight control platforms of

- unmanned aerial vehicle. In *2017 Euromicro Conference on Digital System Design (DSD)*, pages 396–402. IEEE, 2017.
- [17] M. Elsamanty, A. Khalifa, M. Fanni, A. Ramadan, and A. Abo-Ismael. Methodology for identifying quadrotor parameters, attitude estimation and control. In *2013 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, pages 1343–1348. IEEE, 2013.
 - [18] Y. Eraslan, E. Özen, and T. Oktay. The effect of change in angle between rotor arms on trajectory tracking quality of a pid controlled quadcopter. In *EJONS 10th International Conference on Mathematics, Engineering, Natural Medical Sciences*, 05 2020.
 - [19] J. Euchi. Do drones have a realistic place in a pandemic fight for delivering medical supplies in healthcare systems problems? *Chinese Journal of Aeronautics*, 34(2):182–190, 2021.
 - [20] G. R. Flores, J. Escareño, R. Lozano, and S. Salazar. Quad-tilting rotor convertible mav: Modeling and real-time hover flight control. *Journal of Intelligent & Robotic Systems*, 65(1):457–471, 2012.
 - [21] Y. Govdeli, S. M. B. Muzaffar, R. Raj, B. Elhadidi, and E. Kayacan. Unsteady aerodynamic modeling and control of pusher and tilt-rotor quadplane configurations. *Aerospace Science and Technology*, 94:105421, 2019.
 - [22] I. Grujic and R. Nilsson. Model-based development and evaluation of control for complex multi-domain systems: Attitude control for a quadrotor uav. *Technical Report Electronics and Computer Engineering*, 4(23), 2016.
 - [23] M. Hassanalian and A. Abdelkefi. Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace Sciences*, 91:99–131, 2017.
 - [24] S. Haykin. *Neural networks: a comprehensive foundation*. Prentice-Hall, Inc., 1998.
 - [25] M. Heutger and M. Kückelhaus. Unmanned aerial vehicles in logistics a dhl perspective on implications and use cases for the logistics industry. *DHL Customer Solutions & Innovation, Troisdorf, Germany*, 2014.
 - [26] S. Hochreiter and J. Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
 - [27] R. Jannoura, K. Brinkmann, D. Uteau, C. Bruns, and R. G. Joergensen. Monitoring of crop biomass using true colour aerial photographs taken from a remote controlled hexacopter. *Biosystems Engineering*, 129:341–351, 2015.
 - [28] A. M. Jensen, M. Baumann, and Y. Chen. Low-cost multispectral aerial imaging using autonomous runway-free small flying wing vehicles. In *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*, volume 5, pages V–506. IEEE, 2008.
 - [29] W. Koch, R. Mancuso, R. West, and A. Bestavros. Reinforcement learning for UAV attitude control. *ACM Transactions on Cyber-Physical Systems*, 3(2):1–21, 2019.
 - [30] A. Koehl, H. Rafaralahy, M. Boutayeb, and B. Martinez. Aerodynamic modelling and experimental identification of a coaxial-rotor uav. *Journal of Intelligent & Robotic Systems*, 68(1):53–68, 2012.

- [31] S. N. Kumpati, P. Kannan, et al. Identification and control of dynamical systems using neural networks. *IEEE Transactions on neural networks*, 1(1):4–27, 1990.
- [32] S. Li, Y. Wang, J. Tan, and Y. Zheng. Adaptive RBFNNs/integral sliding mode control for a quadrotor aircraft. *Neurocomputing*, 216:126–134, 2016.
- [33] D. Linehan. *Burt Rutan’s Race to Space: The Magician of Mojave and His Flying Innovations*. Zenith Press, 2011.
- [34] R. Maheswari, R. Ganesan, and K. Venusamy. MeDrone- a smart drone to distribute drugs to avoid human intervention and social distancing to defeat COVID-19 pandemic for indian hospital. *Journal of Physics: Conference Series*, 1964(6):062112, jul 2021.
- [35] R. Mahony, V. Kumar, and P. Corke. Multirotor aerial vehicles: Modeling, estimation, and control of quadrotor. *IEEE Robotics and Automation magazine*, 19(3):20–32, 2012.
- [36] D. Mandic and J. Chambers. *Recurrent neural networks for prediction: learning algorithms, architectures and stability*. Wiley, 2001.
- [37] K. Máthé and L. Buşoniu. Vision and control for UAVs: A survey of general methods and of inexpensive platforms for infrastructure inspection. *Sensors*, 15(7):14887–14916, 2015.
- [38] T. H. G. Megson. *Aircraft structures for engineering students*. Butterworth-Heinemann, 2016.
- [39] H. Mehmood, T. Nakamura, and E. N. Johnson. A maneuverability analysis of a novel hexarotor uav concept. In *2016 International Conference on Unmanned Aircraft Systems (ICUAS)*, pages 437–446. IEEE, 2016.
- [40] A. Minardo. The tandem wing: theory, experiments and practical realisations. 2014.
- [41] M. Misin and V. Puig. Lpv mpc control of an autonomous aerial vehicle. In *2020 28th Mediterranean Conference on Control and Automation (MED)*, pages 109–114, 2020.
- [42] F. Muñoz, I. González-Hernández, S. Salazar, E. S. Espinoza, and R. Lozano. Second order sliding mode controllers for altitude control of a quadrotor UAS: Real-time implementation in outdoor environments. *Neurocomputing*, 233:61–71, 2017.
- [43] K. Muraoka, N. Okada, and D. Kubo. Quad tilt wing vtol uav: Aerodynamic characteristics and prototype flight. In *AIAA Infotech@ Aerospace Conference and AIAA Unmanned... Unlimited Conference*, page 1834, 2009.
- [44] T. OKTAY, U. Metin, H. ÇELİK, and M. KONAR. Pid based hierarchical autonomous system performance maximization of a hybrid unmanned aerial vehicle (huav). *Anadolu University Journal of Science and Technology A-Applied Sciences and Engineering*, 18(3):554–562, 2017.
- [45] M. Okulski and M. Ławryńczuk. Development of a high-efficiency pitch/roll inertial measurement unit based on a low-cost accelerometer and gyroscope sensors. In *2019 24th International Conference on Methods and Models in Automation and Robotics (MMAR)*, pages 657–662. IEEE, 2019.
- [46] M. Okulski and M. Ławryńczuk. Identification of linear models of a tandem-wing

- quadplane drone: Preliminary results. In *Advanced, Contemporary Control*, pages 219–228. Springer, Cham, Switzerland, 2020.
- [47] M. Okulski and M. Ławryńczuk. How much energy do we need to fly with greater agility? energy consumption and performance of an attitude stabilization controller in a quadcopter drone: A modified mpc vs. pid. *Energies*, 15(4):1380, 2022.
 - [48] M. Okulski and M. Ławryńczuk. A small UAV optimized for efficient long-range and VTOL missions: An experimental tandem-wing quadplane drone. *Applied Sciences, spec. issue: Unmanned Aerial Vehicles*, 12(14):7059, 2022.
 - [49] M. Okulski and M. Ławryńczuk. A novel neural network model applied to modeling of a tandem-wing quadplane drone. *IEEE Access*, 9:14159–14178, 2021.
 - [50] R. Pascanu, T. Mikolov, and Y. Bengio. On the difficulty of training recurrent neural networks. In *International conference on machine learning*, pages 1310–1318, 2013.
 - [51] K. Peng, G. Cai, B. M. Chen, M. Dong, K. Y. Lum, and T. H. Lee. Design and implementation of an autonomous flight control law for a uav helicopter. *Automatica*, 45(10):2333–2338, 2009.
 - [52] F. Perez-Grau, R. Ragel, F. Caballero, A. Viguria, and A. Ollero. Semi-autonomous teleoperation of uavs in search and rescue scenarios. In *2017 International Conference on Unmanned Aircraft Systems (ICUAS)*, pages 1066–1074, 2017.
 - [53] P. Razi, J. T. S. Sumantyo, D. Perissin, H. Kuze, M. Y. Chua, and G. F. Panggabean. 3D land mapping and land deformation monitoring using persistent scatterer interferometry (PSI) ALOS PALSAR: Validated by geodetic GPS and UAV. *IEEE Access*, 6:12395–12404, 2018.
 - [54] G. Ryou, E. Tal, and S. Karaman. Multi-fidelity black-box optimization for time-optimal quadrotor maneuvers. *arXiv preprint arXiv:2006.02513*, 2020.
 - [55] J. E. Scott and C. H. Scott. Drone delivery models for medical emergencies. *Delivering Superior Health and Wellness Management with IoT and Analytics*, pages 69–85, 2020.
 - [56] M. N. Shauquee, P. Rajendran, and N. M. Suhadis. Quadrotor controller design techniques and applications review. *INCAS Bulletin*, 13(3), 2021.
 - [57] C. H. Shen, F. Albert, C. Ang, D. J. Teck, and K. Chan. Theoretical development and study of takeoff constraint thrust equation for a drone. In *2017 IEEE 15th Student Conference on Research and Development (SCORED)*, pages 18–22. IEEE, 2017.
 - [58] G. Shi, X. Shi, M. O’Connell, R. Yu, K. Azizzadenesheli, A. Anandkumar, Y. Yue, and S.-J. Chung. Neural lander: Stable drone landing control using learned dynamics. In *2019 International Conference on Robotics and Automation (ICRA)*, pages 9784–9790. IEEE, 2019.
 - [59] J. Shin, H. J. Kim, S. Park, and Y. Kim. Model predictive flight control using adaptive support vector regression. *Neurocomputing*, 73(4-6):1031–1037, 2010.
 - [60] J. E. Sierra and M. Santos. Modelling engineering systems using analytical and neural techniques: Hybridization. *Neurocomputing*, 271:70–83, 2018.
 - [61] P. Tabuada. Event-triggered real-time scheduling of stabilizing control tasks. *IEEE Transactions on Automatic Control*, 52(9):1680–1685, 2007.
 - [62] E. Tal and S. Karaman. Accurate tracking of aggressive quadrotor trajectories using

- incremental nonlinear dynamic inversion and differential flatness. *IEEE Transactions on Control Systems Technology*, 29(3):1203–1218, 2021.
- [63] P. Tatjewski. *Advanced control of industrial processes: structures and algorithms*. Springer Science & Business Media, 2007.
 - [64] K. P. Valavanis and G. J. Vachtsevanos. *Handbook of unmanned aerial vehicles*, volume 1. Dordrecht: Springer Netherlands, 2015.
 - [65] S. Waharte and N. Trigoni. Supporting search and rescue operations with UAVs. In *2010 International Conference on Emerging Security Technologies*, pages 142–147. IEEE, 2010.
 - [66] B. Xu, N. Wang, T. Chen, and M. Li. Empirical evaluation of rectified activations in convolutional network. *arXiv preprint arXiv:1505.00853*, 2015.
 - [67] R.-j. Yan, S. Pang, H.-b. Sun, and Y.-j. Pang. Development and missions of unmanned surface vehicle. *Journal of Marine Science and Application*, 9(4):451–457, 2010.
 - [68] S. Yan, Z. Gu, J. H. Park, and X. Xie. Adaptive memory-event-triggered static output control of ts fuzzy wind turbine systems. *IEEE Transactions on Fuzzy Systems*, 2021.
 - [69] H. Yang, Y. Lee, S.-Y. Jeon, and D. Lee. Multi-rotor drone tutorial: systems, mechanics, control and state estimation. *Intelligent Service Robotics*, 10(2):79–93, 2017.
 - [70] Adding a New Flight Mode to Copter. <https://ardupilot.org/dev/docs/apmcopter-adding-a-new-flight-mode.html>, 2021. Accessed: 2021-11-11.
 - [71] ArduPilot. <http://ardupilot.org/about/>, 2020. Accessed: 2020-09-01.
 - [72] ATEA Concept Design. <https://www.ascendance-ft.com/products/>, 2022. Accessed: 2022-05-10.
 - [73] eCalc - reliable electric drive simulations. <https://www.ecalc.ch/index.htm>, 2022. Accessed: 2022-05-18.
 - [74] eMagic One – An eVTOL that really works. <https://emagic-aircraft.com/>, 2022. Accessed: 2022-05-10.
 - [75] Matlab’s finddelay function reference. <https://www.mathworks.com/help/signal/ref/finddelay.html>, 2021. Accessed: 2021-11-11.
 - [76] Find minimum of constrained nonlinear multivariable function - MATLAB fmincon. <https://www.mathworks.com/help/optim/ug/fmincon.html>, 2020. Accessed: 2020-09-01.
 - [77] Kakute f7 aio v1.5 - holybro. <http://www.holybro.com/product/kakute-f7-aio-v1-5/>, 2022. Accessed: 2022-05-18.
 - [78] Keras: The Python Deep Learning library. <https://keras.io/>, 2020. Accessed: 2020-09-01.
 - [79] MotoCalc Electric Flight Performance Prediction Software. <http://www.motocalc.com/>, 2022. Accessed: 2022-05-18.
 - [80] Tandemwings - Nest of Dragons. <https://www.nestofdragons.net/weird-airplanes/tandemwings/>, 2022. Accessed: 2022-05-18.
 - [81] Nxg-02, raster signal connectors. <https://ninigi.com/gb/en/product/ninigi/raster-signal-connectors/nxg-02/112945/>, 2022. Accessed: 2022-05-18.
 - [82] Airfoil plotter. <http://airfoiltools.com/plotter/index?airfoil=p51dtp-il>, 2022. Accessed: 2022-05-18.

- [83] The quickie q2. <https://www.eaa.org/eea/news-and-publications/eea-news-and-aviation-news/bits-and-pieces-newsletter/03-14-2017-the-quickie-q2>, 2022. Accessed: 2022-05-18.
- [84] API Documentation | TensorFlow Core r2.1. https://www.tensorflow.org/api_docs/, 2020. Accessed: 2020-09-01.
- [85] VL53l1x time-of-flight distance sensor carrier with voltage regulator, 400cm max. <https://www.pololu.com/product/3415>, 2022. Accessed: 2022-05-18.