

**POLITECHNIKA KOSZALIŃSKA
WYDZIAŁ MECHANICZNY
KATEDRA MECHANIKI PRECYZYJNEJ
ZAKŁAD MECHATRONIKI**

mgr inż. Sebastian Głowiński

**IDENTYFIKACJA STANU TECHNICZNEGO
ORAZ PODSTAWY PROGNOZOWANIA
PRACOCHOŃNOŚCI NAPRAW
URZĄDZEŃ MECHANICZNYCH NA PRZYKŁADZIE
EKSPLOATACJI STATKÓW POWIETRZNYCH**

Rozprawa doktorska

**Promotor
prof. nadzw. dr hab. inż.
Tomasz Krzyżyński**

Koszalin 2004

*Pragnę osiągnąć wielki i szlachetny cel,
ale moim głównym obowiązkiem
jest osiągnięcie małych celów
tak jakby były wielkie i imponujące.
(HELLEN KELLER)
(1880 – 1968)*

SPIS TREŚCI

SYMBOLE I OZNACZENIA.....	5
WSTĘP, TEZY, CEL I ZAKRES PRACY	9
ROZDZIAŁ 1 PODSTAWY EKSPLOATACJI STATKÓW POWIETRZNYCH	12
1.1. Ogólna charakterystyka urządzeń mechanicznych – statków powietrznych.....	12
1.2. Eksploatacja urządzeń.....	20
1.3. Systemy wspomaganie procesów eksploatacji statków powietrznych	23
1.4. Proces użytkowania statków powietrznych	27
1.5. Własności otoczenia i wpływ warunków atmosferycznych na proces eksploatacji ...	29
1.6. Zasady obsługi w technice lotniczej.....	33
1.7. Intensywność użytkowania i podatność obsługi	39
ROZDZIAŁ 2 NIEZAWODNOŚĆ W TECHNICIE LOTNICZEJ	45
2.1. Wprowadzenie w problematykę uszkodzeń statków powietrznych	45
2.2. Wskaźniki niezawodności w technice lotniczej.....	48
2.3. Stan techniczny statków powietrznych.....	52
2.4. Jakość w technice lotniczej.....	59
2.5. Identyfikacja stanu technicznego statków powietrznych.....	61
2.6. Materiał statystyczny wykorzystany w badaniach.....	64
ROZDZIAŁ 3 METODY STATYSTYCZNE W PROGNOZOWANIU PRACOCHOŁONNOŚCI NAPRAW	77
3.1. Wstęp	77
3.2. Wybór metody prognozowania.....	81
3.3. Prognozowanie szeregów czasowych.....	87
3.5. Metody wyrównywania wykładniczego	94
3.5.1. Dekompozycja szeregu czasowego.....	102
3.5.2. Periodogram.....	104
3.6. Metoda ARMA i ARIMA.....	106
3.7 Błędy prognoz.....	113

ROZDZIAŁ 4 WYNIKI PROGNOZOWANIA METODAMI STATYSTYCZNYMI	118
4.1. Algorytm prognozowania stosowany w badaniach własnych	118
4.2. Wyniki wyrównywania wykładniczego	120
4.2.1. Wstępna analiza szeregu czasowego	120
4.2.2. Dekompozycja sezonowa badanych szeregów	125
4.2. Wyniki metody ARIMA	146
4.3. Wnioski	168
ROZDZIAŁ 5 PROGNOZA PRACOCHOŃNOŚCI NAPRAW PRZY WYKORZYSTANIU SZTUCZNYCH SIECI NEURONOWYCH.....	170
5.1. Ogólna charakterystyka sieci neuronowych	170
5.2. Prognozy pracochłonności napraw przy wykorzystaniu SSN	181
5.3. Wnioski	194
ROZDZIAŁ 6 ZAKOŃCZENIE	196
6.1. Podsumowanie	196
6.2. Perspektywy dalszych badań	197
LITERATURA.....	199
SPIS RYSUNKÓW	204
SPIS TABEL.....	209
ZAŁĄCZNIK	211

SYMBOLE I OZNACZENIA

Do rozdziału 1 i 2

<i>Pracochłonność</i>	- zmienna opisująca naprawy wszystkich statków powietrznych;
<i>Płatowiec</i>	- zmienna opisująca pracochłonność napraw płatowca;
<i>Silnik</i>	- zmienna opisująca pracochłonność napraw silnika;
<i>URE</i>	- zmienna opisująca pracochłonność napraw urządzeń radioelektronicznych;
<i>Osprzęt</i>	- zmienna opisująca pracochłonność napraw urządzeń osprzętowych;
P_e	- potencjał eksploatacyjny;
E_e	- energia eksploatacyjna;
T^*	- temperatura powierzchni płatowca;
T_H	- temperatura powietrza na wysokości H;
M_a	- liczba Macha;
λ_t	- intensywność użytkowania;
Δt	- przedział czasu pracy statku powietrznego;
$\Delta L_p = Z$	- resurs;
K_t	- pracochłonność przypadająca na godzinę lotu;
K_{pl}	- pracochłonność obsługiwanego planowego;
K_n	- pracochłonność obsługiwanego nieplanowego;
T_n	- średni czas naprawy;
t_i	- czas usuwania uszkodzeń;
n	- liczba uszkodzeń;
$R(t)$	- nieuszkodzalność;
$R_g(t)$	- prawdopodobieństwo niewystąpienia stanu granicznego;
$R_z(t)$	- prawdopodobieństwo niewystąpienia stanu uszkodzeń, których skutkiem jest niewykonanie zadania;
λ	- intensywność uszkodzeń;
$\lambda_B(t)$	- intensywność uszkodzeń powodująca zawodność bezpieczeństwa;
$\lambda_n(t)$	- intensywność naprawy;
$\lambda_0(t)$	- intensywność obsługi;
q	- prawdopodobieństwo uszkodzenia;
T_{1000}	- okres trwałości ($T=1000$ godzin);
$\Lambda(t)$	- funkcja wiodąca rozkładu prawdopodobieństwa czasu poprawnej pracy;
$\Lambda_B(t)$	- funkcja wiodąca rozkładu bezpieczeństwa;
$\Lambda_g(t)$	- funkcja wiodąca rozkładu trwałości;
$\Lambda_0(t)$	- funkcja wiodąca rodzaju obsługi;
$\Lambda_z(t)$	- funkcja wiodąca niewykonania zadania
t_k	- czas wycofania urządzenia z systemu eksploatacji;
$Q_B(t)$	- zawodność bezpieczeństwa;

r_B	- prawdopodobieństwo niewystąpienia zawodności bezpieczeństwa;
E	- efektywność niezawodnościowa (skuteczność);
D	- odpowiedniość statku powietrznego;
$F_n(t)$	- wskaźnik naprawialności;
$F_0(t)$	- obsługiwalność;
$F_n(t)$	- wskaźnik naprawialności;
$MTBF$	- średni czas pracy bez uszkodzeń (Mean Time Between Failure);
$MTTR$	- średni czas naprawy (Mean Time To Repair);
η	- wskaźnik gotowości technicznej;
T	- zasób pracy urządzenia;
z	- wielkość zużycia;
z_d	- umowne zużycie przy docieraniu;
z_g	- zużycie graniczne;
u	- prędkość zużycia elementu;
z_1, z_2	- wielkości zużycia elementu odpowiednio w czasie t_1 i t_2 ;
$\xi(t)$	- stan techniczny statku powietrznego;
$\xi_m(t)$	- stan techniczny zespołów statku powietrznego;
$\xi_{mn}(t)$	- stan techniczny podzespołów statku powietrznego;
$x(t)$	- oddziaływania destrukcyjne na statek powietrzny;
$g(t)$	- oddziaływania odnawiające statek powietrzny;
Y_{wy}	- parametry wyjściowe świadczące o cechach stanu;
$X = [x_1, x_2, \dots, x_n]$	- wektor stanu technicznego;
Δy_i	- odchyłka od wartości nominalnej dla i -tego parametru stanu technicznego;
\bar{x}	- średnia arytmetyczna;
M_x	- mediana;
\hat{S}_x^2	- wariancja;
\hat{S}_x	- odchylenie standardowe;
\hat{A}_x	- skośność;
\hat{C}_x	- kurtoza;
\hat{V}_x	- współczynnik zmienności.

Do rozdziału 3 i 4

Y_t	- stan zmiennej Y w momencie lub okresie t ;
y_t^*	- prognoza zmiennej Y wyznaczona na okres t ;
S^*	- średni kwadratowy błąd prognozy ex post;
w_{t+1}	- przyrost funkcji trendu;
\bar{w}	- średnia przyrostów funkcji trendu;
C_{t+1}^n	- wagi harmoniczne realizujące postulat postarzania informacji;

s_w	- odchylenie standardowe przyrostów trendu pełzającego;
y_T^*	- prognoza punktowa na okres T ;
P	- przedział prognozy;
$\alpha, \beta, \gamma, \sigma$	- parametry wygładzania modeli;
F_{t-1}	- wygładzona wartość zmiennej prognozowanej na okres $t-1$;
S_{t-1}	- wygładzona wartość przyrostu trendu na okres $t-1$;
C_{t-1}	- ocena wskaźnika sezonowości na okres $t-1$;
z_t	- surowe wskaźniki sezonowości;
C_t	- czyste wskaźniki sezonowości;
T_1	- początkowa wartość trendu;
$S_{w(t)}$	- wyrównany wykładniczo wskaźnik sezonowości;
x_t	- wartość obserwowana szeregu czasowego w okresie t ;
ε_t	- składnik losowy;
I	- intensywność
φ, θ	- parametry modeli ARIMA;
p, q, ps, qs	- wielkość opóźnienia w modelach ARIMA;
d, ds	- krotność różnicowania w modelach ARIMA;
AR	- modele autoregresji;
MA	- modele średniej ruchomej;
$ARIMA$	- modele autoregresji i średniej ruchomej;
ACF	- funkcja autokorelacji;
$PACF$	- funkcja autokorelacji cząstkowej;
e_t	- błędy ex post;
ME	- średni błąd
MAE	- średni błąd bezwzględny;
MSE	- błąd średniokwadratowy;
MPE	- średni błąd procentowy;
$MAPE$	- średni bezwzględny błąd procentowy;
$MSPE$	- procentowy błąd średniokwadratowy;
$RMSE$	- pierwiastek błędu średniokwadratowego;
$RMSPE$	- pierwiastek procentowego błędu średniokwadratowego;
SE	- błąd standardowy;
SSE	- suma błędów kwadratowych;
SS	- wartość kary;
U_1	- miara błędów systematycznych;
U_2	- miara rozbieżności;
U_3	- miara niezgodności kierunku zmian szeregów;
I^2	- współczynnik rozbieżności Theil'a;
\hat{I}^2	- względny współczynnik rozbieżności Theil'a;

Do rozdziału 5

<i>SSN</i>	- sztuczna sieć neuronowa;
x_1, x_2, \dots, x_n	- wartości wejściowe sieci neuronowej;
<i>MLP</i>	- perceptrony wielowarstwowe;
<i>RBF</i>	- sieci o radialnych funkcjach bazowych;
<i>GRNN</i>	- sieci realizujące regresję uogólnioną;
<i>b</i>	- błąd sieci;
<i>B</i>	- funkcja błędu sieci neuronowej;

WSTĘP, TEZY, CEL I ZAKRES PRACY

Eksploatacja urządzeń mechanicznych zajmuje ważne miejsce w życiu i działalności człowieka tworzącego współczesną cywilizację. Jednym z podstawowych celów badań naukowych w tej dziedzinie jest poszukiwanie i analizowanie powiązań występujących między zjawiskami występującymi podczas eksploatacji urządzeń. W lotnictwie statki powietrzne są zaliczane do najważniejszych urządzeń mechanicznych, choć oczywiście bez urządzeń do odnowy, diagnostycznych oraz bezpośredniej obsługi eksploatacja statków powietrznych byłaby niemożliwa.

Specyfika eksploatacji techniki lotniczej, w tym w szczególności eksploatacja statków powietrznych ponadto polega na nieustannym podejmowaniu decyzji, m.in. na ciągłym śledzeniu zmian wskaźników niezawodności i bezpieczeństwa, doskonaleniu metod badań eksploatacyjnych i opracowywaniu doskonalszych metod eksploatacji. Niezbędnym warunkiem w tej dziedzinie jest proces prognozowania. Zagadnienie to jest rzadko ujmowane w pracach dotyczących eksploatacji statków powietrznych. W celu wzbogacenia dotychczasowego dorobku w tej dziedzinie o nowe, oryginalne rezultaty, autor w niniejszej rozprawie przedstawia problemy dotyczące prognozowania w procesie eksploatacji i w procesie usuwania awarii statków powietrznych. Główna trudność w podjęciu decyzji wiąże się z tym, że w momencie jej ustalania nie można jednoznacznie określić, jaką konkretną korzyść przyniesie ona w przyszłości. Decyzje dotyczące przyszłej działalności osób eksploatujących statki powietrzne mogą być wiarygodne, jeśli ich wybór jest oparty na prognozach. Co więcej, prognozy nie są sądem stanowczym. Systematyczne podejście prognostyczne może prowadzić do uzyskania konkretnych korzyści, jeśli prognozy zostaną użyte właściwie. Problemy dotyczące eksploatacji urządzeń i prognoz ich niezawodności oraz trwałości można znaleźć m.in. w pracach: [Kam199], [Kli1998], [Szy1998] oraz [Kno2002].

Prezentowana rozprawa powstała w związku z potrzebą wypełnienia luki metodycznej istniejącej w naukowym warsztacie badawczym, dotyczącej identyfikacji stanu i prognozowania pracochłonności usuwania awarii urządzeń mechanicznych – statków powietrznych. W tym miejscu celowe wydaje się zdefiniowanie pojęcia pracochłonności. Według Słownika Współczesnej Polszczyzny pracochłonność jest definiowana jako „*ilość pracy, wysiłku włożona w wykonanie jakiejś czynności*” [Zgó2001]. Natomiast ze względu ekonomicznego pracochłonnością jest „*ilość pracy jaka jest potrzebna lub wykorzystana do wytworzenia jednostki produkcji lub określonego dobra, wyrażana w jednostkach pracy na jednostkę produkcji*”. Bliskoznacznym wyrazem pracochłonności jest pojęcie czasochłonności, które jest definiowane jako „*ilość czasu potrzebna do wykonania czegoś*”. **W niniejszej rozprawie pracochłonność jest rozpatrywana jako liczba godzin potrzebna na usunięcie jednej lub większej ilości awarii.** Liczba publikacji krajowych w tej dziedzinie jest niewielka. Całościowe ujęcie systemu eksploatacji technicznej, zarówno w fazie projektowania jak i eksploataowania statków powietrznych zawarto

w opracowaniach profesora Lewitowicza [Lew2001] i [Lew2003]. Statystykę awarii i niesprawności statków powietrznych w polskim lotnictwie można znaleźć w [Zag1996], w którym zaprezentowano prawdopodobieństwa wystąpienia stanów awaryjnych oraz możliwość ich zaistnienia w zależności od elementu konstrukcji wybranych typów statków powietrznych. Interesujące artykuły na temat utraty statków powietrznych w czasie operacji powietrznej zamieszczono również w [Tom1999/2] oraz [Tom2000]. Połączenie podstawowych metod statystyki wraz z metodyką planowania eksperymentów naukowych i możliwością wykorzystania programów komputerowych, zaprezentowane w [Kuk2000], także również stanowiły inspirację do podjęcia trudu napisania niniejszej rozprawy.

Z przeprowadzonych przez autora badań, symulacji oraz z zaprezentowanych powyżej rozważań wynika teza niniejszej rozprawy, którą można sformułować następująco:

Istnieją modele prognostyczne, które z określoną dokładnością są w stanie przewidzieć przyszłe wielkości pracochłonności usuwania awarii na podstawie zgromadzonych danych.

W związku z tym, że z uzyskanych prognoz należy wyciągnąć wnioski, celowe wydaje się rozstrzygnięcie kwestii, którą można sformułować następująco:

Istnieje możliwość identyfikacji stanu technicznego eksploatowanych statków powietrznych na podstawie uzyskanych wyników prognoz.

Celem rozprawy jest natomiast:

1. *Przedstawienie problemów identyfikacji stanu technicznego urządzeń mechanicznych według resursu;*
2. *Opracowanie algorytmu prognozowania pracochłonności napraw przy wykorzystaniu modeli wyrównywania wykładniczego, modeli ARIMA i sieci neuronowych;*
3. *Przedstawienie modeli opisujących pracochłonność napraw, określenie dopuszczalności oraz jakości prognoz, oraz porównanie ich z wartościami rzeczywistymi;*
4. *Opracowanie koncepcji wykorzystania optymalnych prognoz pracochłonności napraw w eksploatacji urządzeń mechanicznych.*

Z uwagi na fakt, że prezentowana tematyka dotyczy trzech odmiennych dziedzin badawczych: eksploatacji, niezawodności oraz prognozowania, przegląd literatury zostanie dokonany w odpowiednich rozdziałach pracy.

Zgodnie z powyższym w pierwszym rozdziale rozprawy przedstawiano problematykę związaną z eksploatacją urządzeń mechanicznych, wyjaśniono podstawowe pojęcia oraz zaprezentowano podejście do obsługi według resursów i według stanu technicznego.

Rozdział drugi poświęcono niezawodności urządzeń mechanicznych, ze szczególnym uwzględnieniem zasad obsługi w technice lotniczej. Ponadto zaprezentowano w nim materiał statystyczny związany z awariami wybranego typu statku powietrznego, wykorzystany następnie do badań nad prognozowaniem pracochłonności napraw.

W rozdziale trzecim zawarto wybrane zagadnienia prognozowania oraz modele i rodzaje błędów prognozowania.

Rozdział czwarty poświęcony jest prognostycznemu ujęciu pracochłonności napraw. Celem tego rozdziału jest wykazanie możliwości prognozowania pracochłonności napraw na podstawie zgromadzonych danych dotyczących eksploatacji w latach poprzednich. W rozdziale tym przedstawiono algorytm prognozowania pracochłonności usuwania awarii oraz dwie metody prognozowania: metodę wyrównywania wykładniczego i metodę ARIMA wraz z wynikami prognoz i z wykresami. Przedstawiony algorytm prognozowania stanowi propozycję toku postępowania w przypadku konieczności wykonania prognoz pracochłonności przy usuwaniu awarii statków powietrznych. Umożliwi to planowanie m.in. okresów urlopowych oraz jeśli nastąpi gwałtowny wzrost pracochłonności, będzie sygnałem do podjęcia określonych czynności.

W rozdziale piątym przedstawione są rodzaje sieci neuronowych wykorzystane do predykcji oraz modele sieci neuronowych do prognozowania pracochłonności napraw statków powietrznych. Uzyskane przy ich pomocy wyniki prognoz i wykresy umożliwiają porównanie z metodami wyrównywania wykładniczego i ARIMY.

Autor ma nadzieję, że przeprowadzone i opisane w pracy badania przyczynią się, choćby w niewielkim stopniu do zasygnalizowania problemu obecnie bardzo niepokojącego, czyli kwestii eksploatacji przestarzałego sprzętu lotniczego. Pomimo tego, że producent w większości przypadków przewidział długie okresy eksploatacji, występująca w praktyce częstotliwość awarii wpływa niekorzystnie na ponoszone w związku z tym koszty napraw.

ROZDZIAŁ 1


PODSTAWY EKSPLOATACJI STATKÓW POWIETRZNYCH

1.1. Ogólna charakterystyka urządzeń mechanicznych – statków powietrznych

Dzięki wykorzystaniu urządzeń mechanicznych człowiek może w sposób świadomy zmieniać świat i swoje otoczenie zgodnie ze swoimi potrzebami. Według [Okr1980] eksploatacja urządzeń mechanicznych to proces działania o złożonym charakterze technicznym, mający na celu przekazywanie urządzeniom wielu złożonych czynności wykonywanych uprzednio przez człowieka, prowadzący do zmiany stanu pewnego obszaru rzeczywistości. Działanie człowieka sprowadza się, więc nie tylko do tworzenia coraz to doskonalszych urządzeń, ale również do nadzoru nad ich pracą.

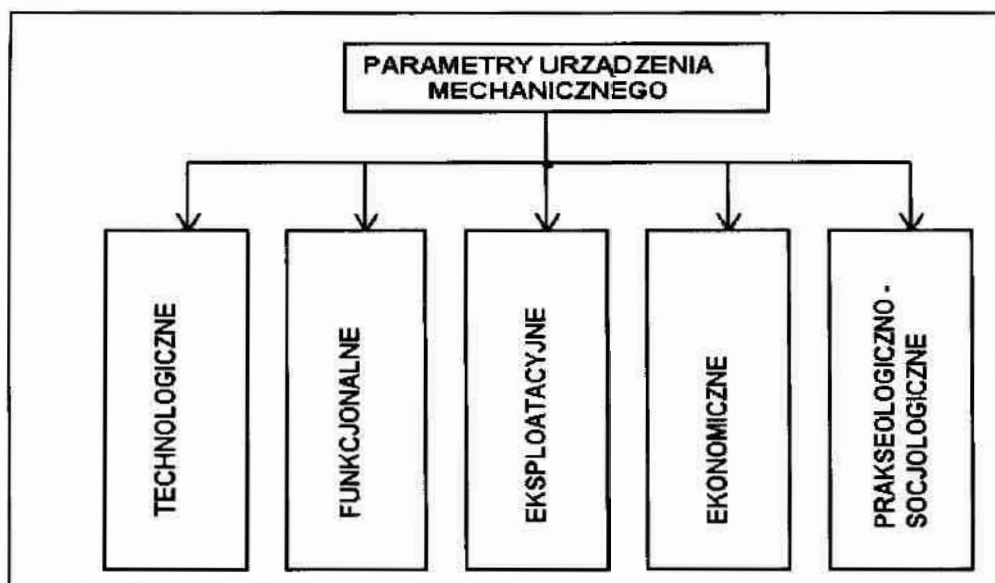
W eksploatacji statków powietrznych wyróżnia się kilka okresów:

- a) *okres projektowania*,
- b) *okres wytwarzania prototypu urządzenia*,
- c) *okres testowania prototypu*,
- d) *okres wytwarzania urządzenia (produkcja)*,
- e) *okres wprowadzania urządzenia do eksploatacji (programowanie)*,
- f) *okres użytkowania urządzenia*,
- g) *okres wycofywania z eksploatacji*,
- h) *okres recyklingu (złomowania)*.



Rys. 1.1: Okresy eksploatacji urządzeń mechanicznych.

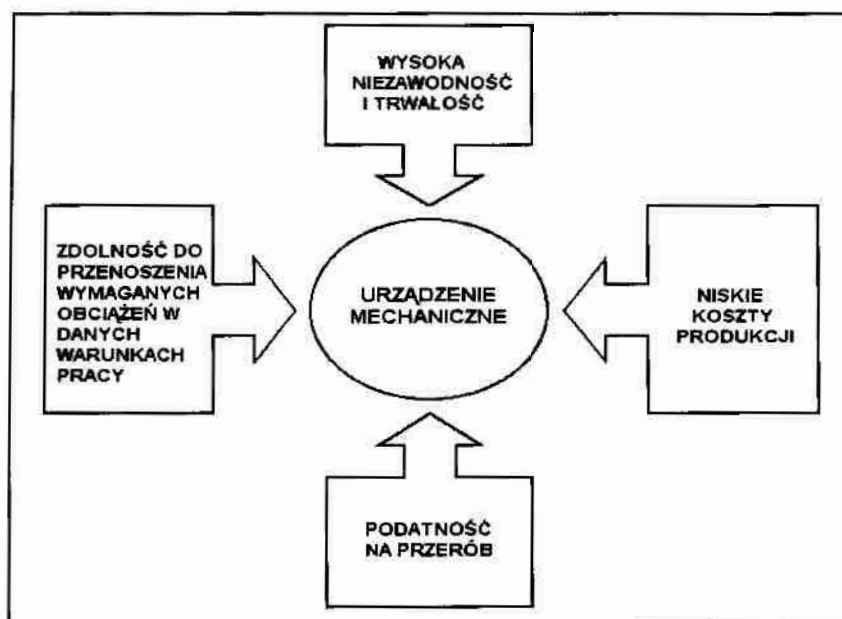
Na rys. 1.1 przedstawiono okresy „życia” statku powietrznego (skale osi rzędnych oraz odciętych nie odwzorowują wartości rzeczywistych). W okresie projektowania, którego czasochłonność, w zależności od stopnia skomplikowania urządzenia wynosi od 6 do 12 miesięcy, następuje określenie potrzeb, wykonanie niezbędnych obliczeń uwzględniających przewidywane obciążenia eksploatacyjne, dobór materiałów, kształtu i wymiarów elementów urządzenia mechanicznego, określenie prac badawczych, wykonanie rysunków, jak również oszacowanie wskaźników efektywności urządzenia w procesie jego użytkowania. Koszt tego okresu wynosi z reguły około 1-2% całkowitych kosztów względnych, w stosunku do kosztów eksploatacji 100 egzemplarzy urządzeń przyjętych za 100%. Okresy wytwarzania i testowania prototypu urządzenia, trwające około 2-5 lat w przypadku konstrukcji lotniczych, obejmują skonstruowanie wymaganej do prób i testowania próbki urządzeń. Koszty wytwarzania i testowania prototypu wynoszą około 30% kosztów względnych. Okresy produkcji, wprowadzania urządzeń do użytkowania, przeszkolenia pracowników obsługujących urządzenia (obejmujący okres czasu od 5 do 7 lat, wliczając czas przeszkolenia załogi obsługującej) wynoszą 50% całkowitych kosztów względnych. Najważniejszym z punktu widzenia użytkownika jest okres eksploatacji urządzeń. Obejmuje on użytkowanie, obsługiwanie, odnowę – remont, transport oraz magazynowanie urządzeń. Czas użytkowania trwający od 10 do 30 lat obejmuje koszty nawet do 100 % całkowitych kosztów względnych. W czasie okresu eksploatacji następuje postulowanie niezbędnych zmian konstrukcyjnych i technologicznych ze względu na warunki użytkowania. Okresem kończącym użytkowanie urządzenia jest wycofywanie z eksploatacji i złomowanie. Związane z tym koszty wynoszą od 2 do 3% całkowitych kosztów względnych, a okres czasu z tym związany wynosi od 2 do 3 tygodni [Lew2001].



Rys. 1.2: Parametry urządzeń mechanicznych.

Należałoby w tym miejscu wyjaśnić pojęcie *parametru*, który jest wielkością zachowującą stałe wartości w określonych warunkach. Do najważniejszych parametrów związanych z użytkowaniem urządzeń mechanicznych należą te przedstawione na rys. 1.2.

Do parametrów technologicznych należy zaliczyć wydajności pracy urządzeń, czasy przerw technologicznych oraz wartości użytkowe. Za parametry funkcjonalne uważa się czas pracy, eksploatacji, przeciętny czas sprawności, niezawodność urządzenia oraz zużycie energii na cele eksploatacyjne. Parametry eksploatacyjne określają resursy urządzenia, przewidywany czas eksploatacji, normy międzyobsługowe, pracochłonność lub czas poszczególnych rodzajów obsługa, które są określone przez konstruktora w fazie projektowania lub testowania urządzenia. Natomiast do parametrów ekonomicznych zalicza się jednostkowy koszt użytkowania urządzenia na godzinę pracy, wraz z kosztami poszczególnych rodzajów obsługa, koszty części zamiennych oraz koszty utrzymania załogi. Jest to istotny parametr z punktu widzenia użytkownika. W większości przypadków należy dążyć do minimalizacji kosztów eksploatacji urządzeń przy jednoczesnym zwiększeniu lub utrzymaniu na określonym poziomie bezpieczeństwa osób obsługujących urządzenie. Parametry prakseologiczno – socjologiczne określają liczebność załogi, terminy wykonania zadań, przeciętne zarobki i wydatki, czas przeznaczony na odpoczynek i regenerację oraz wydajność pracowników.



Rys. 1.3: Wymagania stawiane urządzeniom mechanicznym.

Według Lewitowicza [Lew2001] cechy eksploatowanych statków powietrznych można podzielić na dwie grupy: właściwości oraz własności. Właściwość jest cechą, która pozwala odróżnić obiekt od innych. Natomiast własność jest cechą urządzenia wspólną dla wszystkich tej klasy urządzeń, wyrażająca się jako wielkość fizyczna. Własności użytkowe są tworzone w fazie powstawania samolotu. Na własności statku powietrznego zasadniczy wpływ mają materiały, z jakich są one wykonane oraz technologie stanowiące wraz

z materiałem organiczną całość. Do głównych wymagań stawianych materiałom wykorzystywanym do konstruowania w technice lotniczej należy zaliczyć przedstawione na rys 1.3.

Okręglicki [Okr1980] do istotnych własności urządzeń mechanicznych zalicza:

- a) odporność na odkształcenia trwałe,
- b) podatność na odkształcenia sprężyste,
- c) odporność na zużycie ściernie i uszkodzenia powierzchniowe,
- d) odporność na korozję i zmęczenie korozyjne,
- e) zdolność tłumienia drgań,
- f) podatność powierzchni stykających się na zwilżanie i smarowanie,
- g) zdolność powierzchni do wymiany ciepła,
- h) trwałość pasowań,
- i) zdolność zachowania wymaganych wartości w obszarze tolerancji,
- j) sprawność mechaniczną urządzenia.

Do polepszenia własności materiałów oraz urządzeń prowadzą nowe technologie. We współczesnych konstrukcjach urządzeń mechanicznych wyraźnie zauważa się wzrost zastosowania materiałów kompozytowych, jednak w technice lotniczej nadal wykorzystuje się stopy aluminium z kilku powodów:

- a) możliwości modyfikowania stopów,
- b) podatność na przerób,
- c) możliwość opracowania kompozytów na osnowie stopów aluminium,
- d) możliwość wykorzystania wszelkich możliwości obróbki cieplnej w celu uzyskania optymalnych własności użytkowych,
- e) stosunkowo niewielka masa w porównaniu z innymi materiałami.

Gruszczyński [Lew1993/2] zwraca uwagę na coraz szersze stosowanie metod metalurgii proszkowej w połączeniu z technologiami gwałtownego chłodzenia. Pozwala to na otrzymanie stopów, których otrzymanie metodami konwencjonalnej metalurgii ogniowej byłoby niemożliwe. W elementach, w których istotna jest niewielka masa i wytrzymałość na rozciąganie stosuje się tytan. Zastosowanie tytanu umożliwia pracę urządzeń, bądź elementów przy podwyższonych temperaturach do 600°, bez utraty własności projektowych. Jest on odporny na korozję, posiada wysoką wytrzymałość na zmęczenie. Do wad tego materiału, należy zaliczyć to, że jest on trudny technologicznie do obróbki na gorąco. Obecnie rosnącą ważną grupą materiałów stosowanych w urządzeniach mechanicznych o znacznej wartości są materiały kompozytowe. Są to tworzywa monolityczne makroskopowo, będące połączeniem dwu lub więcej składników o wyraźnej granicy rozdziału między nimi. Wadą tych materiałów są wysokie koszty wytwarzania. W konstrukcjach urządzeń ważne miejsce zajmują nadal stale konstrukcyjne stopowe i węglowe. Opracowane w latach 80-tych stale martenzytyczne posiadają bardzo dobre własności mechaniczne. Elementy z nich wykonane nie wymagają dalszej obróbki, ponieważ podczas starzenia nie ulegają wypaczeniu. Należy wspomnieć o powłokach

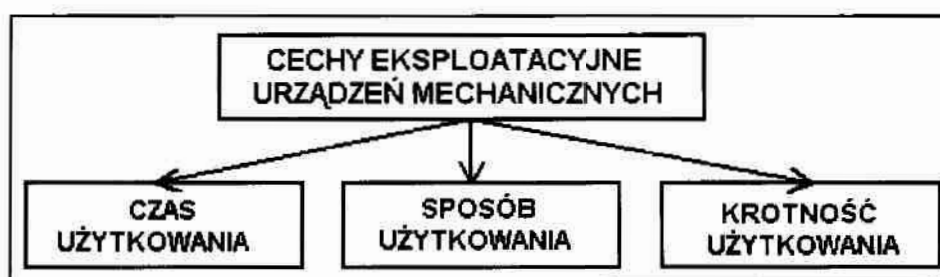
ochronnych stosowanych w niektórych urządzeniach. Należą do nich powłoki aluminiowe, aluminiowo – chromowe oraz powłoki tlenowe – ceramiczne.

Urządzenia mechaniczne można klasyfikować w różny sposób. Ważyńska-Fiok [Waż1990] klasyfikuje je według:

- a) złożoności,
- b) naprawialności,
- c) nadmiarowości,
- d) diagnozowalności.

W urządzeniach sklasyfikowanych według złożoności rozróżnia się urządzenia proste i złożone. W pierwszym przypadku urządzenie może znajdować się jedynie w dwóch stanach: zdatny i niezdatny. Natomiast w drugim przypadku urządzenie może znajdować się w wielu różnych stanach zdatności i w wielu różnych stanach niezdatności, w których spełnia lub nie spełnia wymagań stawianych przez użytkownika. Rozpatrując podział urządzeń według naprawialności wyróżnia się urządzenia naprawialne, gdy naprawa urządzenia po uszkodzeniu przywraca mu stan zdatności oraz nienaprawialne, jeżeli stany niezdatności urządzenia są nieodwracalne, bądź naprawa jest nieopłacalna ze względów ekonomicznych lub innych jak np. brak specjalistów do naprawy, brak części zamiennych. W urządzeniach nadmiarowych istnieją takie elementy, których uszkodzenie nie powoduje przejścia urządzenia w stan niezdatności, natomiast w nienadmiarowych po uszkodzeniu niektórych elementów zaistniała sytuacja powoduje przejście urządzenia w stan niezdatności. Jeśli można określić na podstawie układów diagnostycznych, bądź pewnych symptomów funkcjonowania, w jakim stanie niezawodnościowym znajduje się urządzenie określa się je jako diagnozowalne. Gdy niemożliwe jest rozróżnienie stanów niezawodnościowych urządzenia, uważa się je jako niediagnozowalne.

Z punktu widzenia cech eksploatacyjnych urządzenia mechaniczne mogą być sklasyfikowane według sposobu przedstawionego na rys. 1.4.

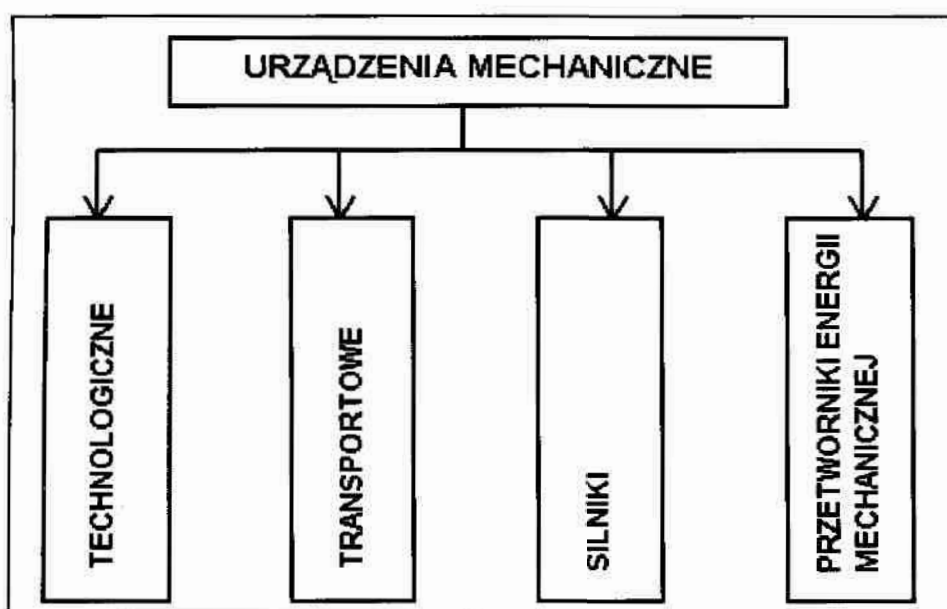


Rys. 1.4: Klasyfikacja urządzeń mechanicznych z punktu widzenia cech eksploatacyjnych.

W urządzeniach sklasyfikowanych według czasu użytkowania wyróżnia się obiekty eksploatowane do pierwszego uszkodzenia (żarówki, bezpieczniki) oraz eksploatowane do osiągnięcia stanu granicznego. W takim przypadku urządzenie mechaniczne jest wycofywane z eksploatacji, jeżeli nakłady na jego obsługiwanie są zbyt duże lub użytkowanie staje się niebezpieczne dla użytkownika. Rozpatrując sposób użytkowania

urządzenia można podzielić na pracujące w sposób ciągły oraz pracujące w sposób przerywany. W pierwszym przypadku zaliczamy do nich baterie akumulatorowe, będące na wyposażeniu statku powietrznego. Oczywiście nie uwzględnia się w tym przypadku przerw wynikających z obsługi okresowych (np. wymiana elektrolitu itp.). Do urządzeń pracujących w sposób przerywany można zaliczyć większość urządzeń eksploatowanych przez człowieka. W urządzeniach sklasyfikowanych według krotności użytkowania wyróżnia się urządzenia jednokrotnego oraz wielokrotnego użytku. Urządzenia jednokrotnego użytku po wykonaniu zadania nie mogą być wykorzystane ponownie. Zalicza się do nich m.in. pociski raketowe stosowane w uzbrojeniu statków powietrznych. Natomiast urządzenia wielokrotnego użytku po wykonaniu określonego zadania mogą być wykorzystane ponownie do realizacji zadań następnych, np. wyrzutnie pocisków raketowych. Po odpaleniu pocisku wyrzutnia może zostać ponownie wykorzystana do odpalania następnych pocisków, oczywiście po wykonaniu określonych obsług.

Ze względu na rodzaj procesu roboczego i funkcje wykonywane przez urządzenie [Okr1980] wyróżnia cztery klasy urządzeń, przedstawione na rys. 1.5.



Rys. 1.5: Klasy urządzeń mechanicznych.

Urządzenia technologiczne przetwarzają surowce lub półwyroby w gotowe wyroby. Następuje przy tym zmiana kształtu, objętości oraz własności chemicznych lub fizycznych. Są to obrabiarki, walcarki, kruszarki, kombajny rolnicze itp. Dzięki wykorzystaniu urządzeń transportowych możemy zmieniać położenie ciał stałych, cieczy lub gazów. Do urządzeń transportowych zalicza się dźwignice, przenośniki, pompy oraz samochody. Do tej klasy zalicza się również statki powietrzne, ponieważ przy ich wykorzystaniu można przenosić uzbrojenie (samoloty myśliwskie, bombowe) lub paliwo (latające cysterny). Silniki przetwarzają różne rodzaje energii na energię mechaniczną naturalną (silniki ciepłne, powietrzne oraz wodne) lub wtórną (silniki pneumatyczne, hydrauliczne i

elektryczne). Przetworniki energii mechanicznej jak sama nazwa wskazuje przetwarzają energię mechaniczną na inny rodzaj energii. Wyróżnia się przetworniki mechaniczno – elektryczne, mechaniczno – hydrauliczne oraz mechaniczno – powietrzne.

Jak wspomniano na wstępie rozdziału do urządzeń mechanicznych należy zaliczyć statki powietrzne. Według [Lew2001] statek powietrzny należy traktować jako złożony zautomatyzowany polienergetyczny system techniczny złożony z następujących systemów i podsystemów:

- a) system napędu:
 - *podsystem silnika,*
 - *podsystem zasilania tlenem silnika,*
 - *podsystem rozruchu,*
 - *podsystem zasilania paliwem,*
 - *podsystem sterowania napędem samolotu,*
- b) system kadłuba samolotu (płatowca):
 - *podsystem podwozia,*
 - *podsystem wentylacji,*
 - *podsystem poszycia zewnętrznego i wewnętrznego,*
- c) system zasilania energią elektryczną:
 - *podsystemy rozdzielcze energii elektrycznej,*
- d) system uzbrojenia:
 - *podsystem uzbrojenia strzeleckiego,*
 - *podsystem uzbrojenia pocisków raketowych klasy powietrze – ziemia,*
 - *powietrze – powietrze oraz powietrze – woda,*
 - *podsystem uzbrojenia bombardierskiego,*
- e) system bezpieczeństwa:
 - *podsystem bezpieczeństwa konstrukcyjnego;*
 - *podsystem bezpieczeństwa zapobiegawczego;*
 - *podsystem bezpieczeństwa eksploatacji;*
 - *podsystem bezpieczeństwa awaryjnego,*
- f) system pilotażowo - nawigacyjny:
 - *autopilot statku powietrznego,*
 - *podsystem pokładowy – komputerowy,*
 - *podsystem nawigacji powietrznej dalekiego i bliskiego zasięgu,*
 - *podsystem pokładowych układów lądowania w różnych sytuacjach,*
 - *podsystem sterowania hamulcami aerodynamicznymi,*
 - *podsystem sterowania podwoziem,*
 - *podsystem odhamowania podwozia,*
 - *podsystem sterowania nieautomatycznego samolotem,*
- g) system oświetlenia wewnętrznego i zewnętrznego,
- h) system rejestracji parametrów lotu (black box).



Rys. 1.6: Systemy statku powietrznego.

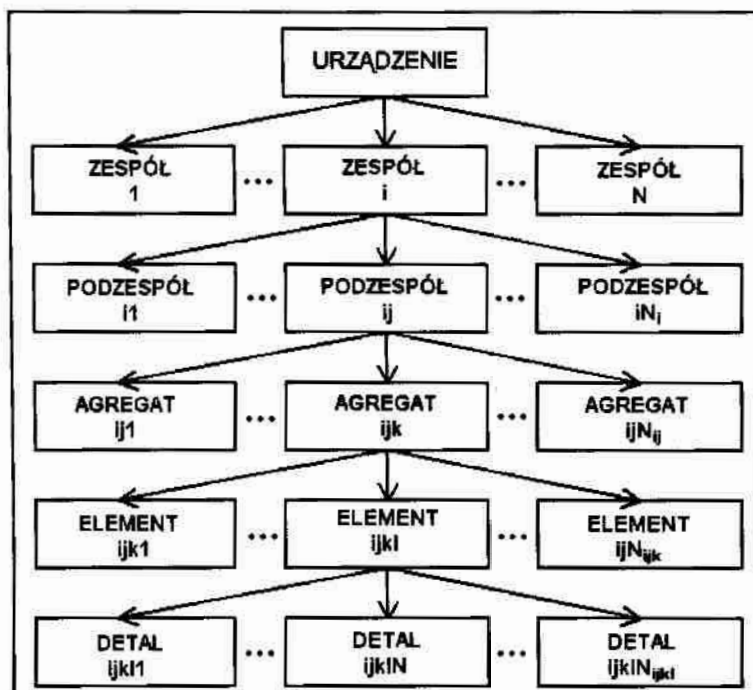
W celu stworzenia powyższych systemów, potrzebne jest współdziałanie wielu specjalistów z dziedziny budowy samolotów, metod ich diagnostyki, praktycznej eksploatacji i oceny pilotażu. Zainstalowane na statku powietrznym mechanizmy przetwarzają różne rodzaje energii, przenoszą ruch jednych ciał w wymagane ruchy innych ciał. Niektóre mechanizmy niejednokrotnie reagują na zmiany prędkości kątowej sprężarki, turbiny silnika, dozując wymaganą dawkę paliwa. Cechą każdego urządzenia jest również pokonywanie występujących oporów ruchu. Okręglicki [Okr1980] opory ruchu dzieli na opory zewnętrzne, pochodzące od użytecznego obciążenia urządzenia oraz opory wewnętrzne, pochodzące od tarcia. Podczas ruchu jałowego urządzenia występują tylko opory wewnętrzne, natomiast podczas ruchu roboczego istnieją obydwa rodzaje oporów. Użytkownikowi każdego urządzenia zależy na minimalizacji oporów, co jest związane ze zmniejszeniem kosztów eksploatacji.

Według [Fig1996] urządzenia mechaniczne można podzielić na:

- a) rodzaje urządzeń,
- b) typy urządzeń,
- c) bloki,
- d) elementy.

Inny podział – ze względu na hierarchiczną strukturę konstrukcyjną systemu przedstawiony jest w [Waż1990]. W takim przypadku system składa się z podsystemów nazywanych zespołami konstrukcyjnymi. Zespoły te składają się z podzespołów urządzeń lub instalacji, a podzespoły z agregatów. Agregaty mogą być nazywane równoważnie blokami lub układami. Rozpatrywane są jako elementy podzespołów. Agregaty dzielą się na elementy, te z kolei na detale. Należy zaznaczyć, że w niektórych przypadkach

i w odniesieniu do konkretnego urządzenia oraz celu i głębokości przeprowadzonej analizy danego zagadnienia, struktura powyższa może ulegać modyfikacjom.




Rys. 1.7: Hierarchiczna struktura konstrukcyjna systemu według [Waż1990].

1.2. Eksploatacja urządzeń

Na wstępie należy zdefiniować pojęcie eksploatacji. Rozważania na temat desygnatu terminu eksploatacja przedstawione są w pracy Powierzy [Pow2001]. Powierza definiuje eksploatację jako „sterowany, losowy proces wyczerpywania zasobu użytkowego obiektu”. Natomiast według [Lew2001] eksploatacją jest „sekwencja zdarzeń losowych wyrażających stany obiektu i ich zmiany, czyli kontrolowany proces losowy wyczerpywania zasobu użytkowego urządzeń. Za eksploatację uważa się zespół celowych działań organizacyjno – technicznych i ekonomicznych ludzi z urządzeniem mechanicznym oraz wzajemne relacje występujące pomiędzy nimi od chwili przejęcia obiektu do wykorzystania zgodnie z przeznaczeniem aż do jego likwidacji”. Poprzez eksploatację można rozumieć wykorzystywanie bogactw naturalnych, wyzysk. Bardziej szczegółowym pojęciem jest eksploatacja urządzeń mechanicznych. Według Koniecznego [Kon1975] poprzez eksploatację urządzenia należy rozumieć „użytkowanie lub obsługiwanie urządzenia i działanie w łańcuchu eksploatacji, które nie jest jego projektowaniem lub wytwarzaniem”. Dwiliński [Dwi1991] eksploatacją urządzeń mechanicznych nazywa „działanie, w którym przedmiotem działania jest określone urządzenie (obiekt) i którego to działania celem jest udostępnienie sobie przez człowieka potrzebnej mu ilości z posiadanego przez urządzenie zasobu możliwości funkcjonowania”. Pomimo, że

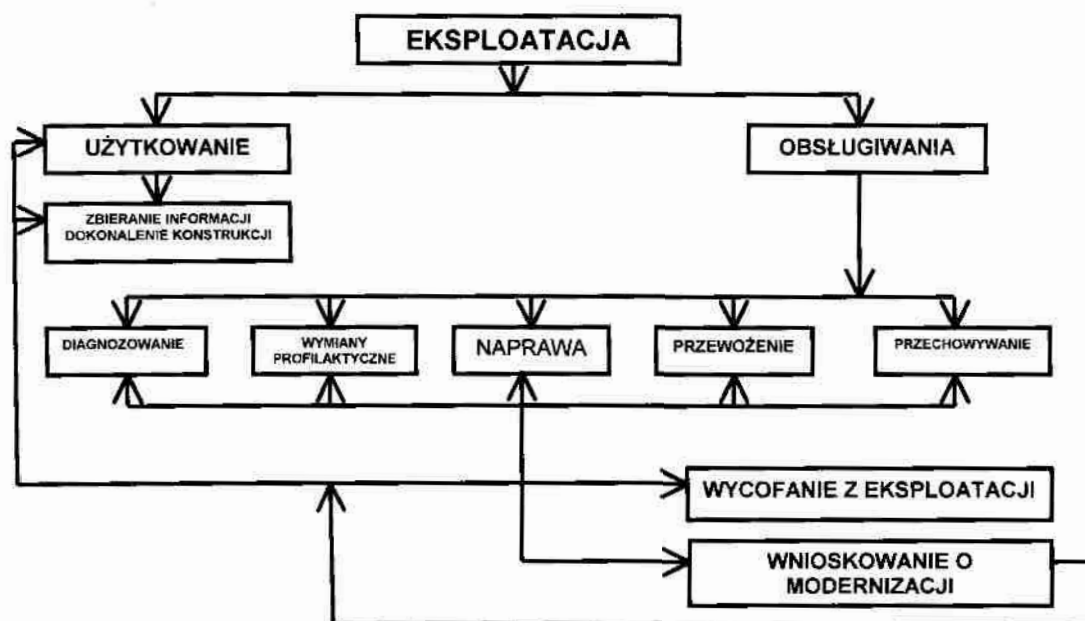
przedstawione definicje pojęcia eksploatacja są poprawne, według autora niniejszej rozprawy najbardziej trafną jest definicja Koniecznego [Kon1975].



Rys. 1.8: Model systemu antropotechnicznego.

We współczesnej eksploatacji statków powietrznych układy mechaniczne należy rozpatrywać jako systemy antropotechniczne: urządzenie mechaniczne – człowiek – środowisko. Właściwości systemu antropotechnicznego opisane zostały w: [Dąb2000/1]; [Dąb2000/2] oraz [Dąb2001]. Podstawowa struktura systemu antropotechnicznego przedstawiona jest na rys. 1.8. Przy takim podejściu eksploatacja jest podporządkowana określone celowi, np. osiągnięcie zysku ekonomicznego – w przypadku przewozu pasażerów oraz zysku pozaekonomicznego – w przypadkach takich jak zadania bojowe lotnictwa myśliwskiego lub bombowego. Do tego należy zaliczyć zakłócenia takie jak awarie sprzętu, spiętrzenie zadań itp. Prawidłowe określenie charakteru występujących zależności jest bardzo ważne, ponieważ pozwala na wcześniejsze reagowanie w przypadku sytuacji krytycznych. Szczególnie dotyczy to urządzeń ważnych dla obronności państwa takich jak statki powietrzne eksploatowane w wojsku. Część awarii jest spowodowana zawodnością człowieka, niewłaściwie wykonanym remontem, bądź niewłaściwą eksploatacją urządzeń.

Według [Fig1996] eksploatacja urządzeń polega na utrzymaniu jego parametrów, sterowaniu jego działaniem przy zachowaniu optymalnego stosunku uzyskanych efektów do zużytych materiałów, energii włożonej pracy personelu obsługującego. Przy takim podejściu eksploatowane urządzenie może przebywać w dwóch stanach: użytkowania oraz obsługiwanego. W pierwszym przypadku dotyczy to realizacji przez urządzenie zadań zgodnie z dokumentacją eksploatacyjną. Natomiast obsługiwane urządzenie dotyczy szeregu przedsięwzięć związanych z utrzymaniem jego w stanie gotowości. Dotyczy to konserwacji, naprawy, kontroli stanu technicznego itp. Problemy dotyczące obsługiwanego zostaną szerzej omówione w podrozdziale 1.6.



Rys. 1.9: Proces eksploatacji urządzenia [Fig1996].

Słowiński [Sło1996] eksploatację urządzeń mechanicznych uważa za ostatni element operacyjny w procesie zaspokajania potrzeb. Główny wysiłek osób eksploatujących urządzenia mechaniczne powinien być skierowany na zastosowanie najlepszej i najefektywniejszej strategii eksploatacji, która powinna wywołać zamierzony efekt. Tylicki [Ty11998] pojęcie „najlepsze” wiąże z przyjęciem odpowiednich kryteriów i rozpatrzeniem problemów w kategoriach poszukiwania optymalnych rozwiązań. Niezbędne wydaje się zastosowanie takiej strategii eksploatacji i obsługi, która minimalizowałaby czas przestoju spowodowany awariami. Eksploatacji urządzeń mechanicznych powinna towarzyszyć ekonomia i niezawodność.

Konieczne w tym miejscu wydaje się zdefiniowanie pojęć *potencjał eksploatacyjny* (*pe*) oraz *energia eksploatacyjna* (*ee*). Według Lewitowicza [Lew2001] „*potencjał eksploatacyjny definiuje zasób możliwości wytwórczych statków powietrznych*”, tkwiących w nim, a wydobywanych w czasie użytkowania. Inaczej potencjałem eksploatacyjnym statku powietrznego można określić zasób wykonania zadań lotniczych. Natomiast „*energia eksploatacyjna określa energię, którą wydobywa się z eksploatowanych statków powietrznych w procesie eksploatacji*”. Wydaje się zasadne stwierdzenie, że energia eksploatacyjna znajduje się w każdym eksploatowanym urządzeniu mechanicznym, bez względu czy jest to statek powietrzny czy pompa paliwowa. Poprzez użytkowanie urządzeń mechanicznych następuje zmniejszanie potencjału eksploatacyjnego, przez co uzyskiwana jest energia eksploatacyjna. Poprzez odtwarzanie potencjału eksploatacyjnego energia eksploatacyjna zostaje akumulowana. Zastosowanie przez użytkownika urządzeń mechanicznych odpowiedniej strategii eksploatacji umożliwia właściwe sterowanie potencjałem eksploatacyjnym. Należy zwrócić uwagę na to, że potencjał eksploatacyjny

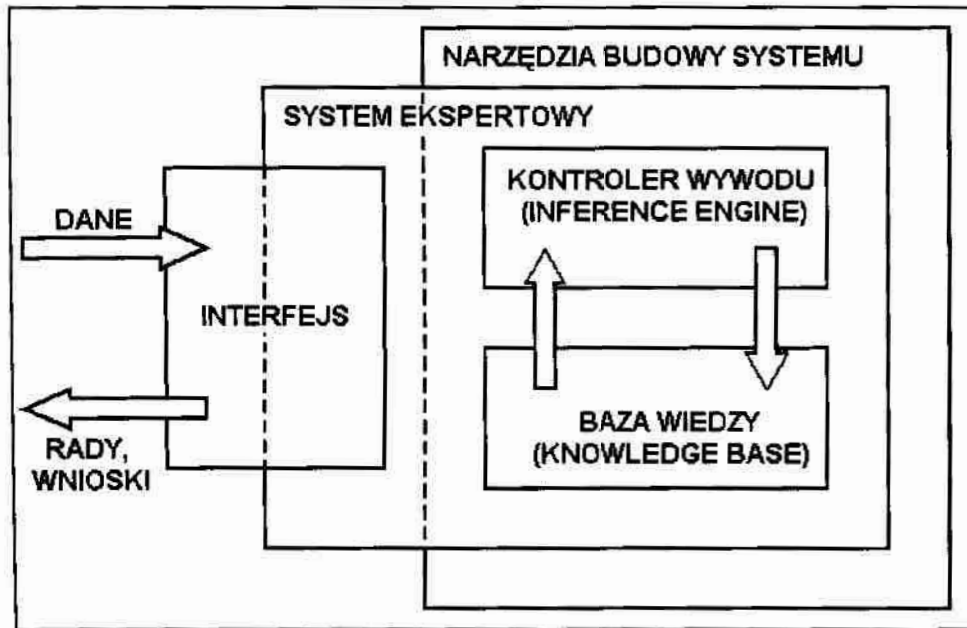
musi być (zgodnie z technologią) podtrzymywany lub odtwarzany. W niektórych przypadkach istnieje możliwość jego powiększania, np. poprzez wykonanie modernizacji. Brak właściwej strategii powoduje powstanie eksploatacyjnych sytuacji konfliktowych. Wiąże się z tym ryzyko nieosiągnięcia zamierzonego celu eksploatacji. Rozwiązywanie problemów z tym związanych polega na identyfikacji, modelowaniu, wartościowaniu oraz optymalizacji sytuacji problemowej. Wykorzystuje się do tego wiedzę ekspertów oraz odpowiednie algorytmy postępowania (m.in. algorytm W. Miszalskiego; algorytm Lemke–Howsona), które wraz z przykładowymi obliczeniami przedstawiono w [Lew2001].

1.3. Systemy wspomaganie procesów eksploatacji statków powietrznych

Opisane w poprzednim podrozdziale podejście systemowe urządzenie – człowiek – środowisko zmusza nie tylko do analizy urządzeń mechanicznych, ale również do analizy zachowań osób obsługujących. Dotyczy to zwłaszcza skomplikowanych urządzeń, jakimi są statki powietrzne. Rozwój dzisiejszej techniki pozwala na budowanie rozwiniętych systemów, które po wprowadzeniu do nich reguł wnioskowania przetwarzają ogromne strumienie informacji o eksploatowanym urządzeniu, wspomagając decyzje użytkowe, diagnostyczne oraz obsługowe. Według [Kow1994] decydującym argumentem za wdrażaniem takich systemów są względy ekonomiczne. Eksploatacja współczesnej techniki jest bardzo kosztowna, a zastosowanie systemów ekspertowych znacznie zmniejsza koszty oraz pracochłonność obsług urządzeń mechanicznych. Co więcej, w wielu sytuacjach człowiek nie mógłby swoimi zmysłami ogarnąć całego problemu. Stworzenie systemów ekspertowych, których działanie można porównać z zachowaniem i rozumowaniem człowieka w takich samych sytuacjach, znacznie ułatwia pracę inżynierów. System ekspertowy jest poprawny, jeśli daje on dobre rezultaty, rozwiązuje zadania w czasie dopuszczalnym i dysponuje strategiami umożliwiającymi imitowanie wiedzy i intuicji eksperta, uzyskanej w wyniku wieloletniego doświadczenia [Mul1996]. Według [Chr1995] jest to komercyjny program komputerowy, składający się z trzech niezależnych fizycznie, współpracujących ze sobą części: bazy wiedzy, kontrolera wyводу, interfejsu, który ma na celu zastąpienie pracy eksperta w danej dziedzinie. Budowę typowego systemu ekspertowego przedstawiono na rys. 1.10.

Baza wiedzy zawiera wiedzę o dziedzinie i o podejmowaniu decyzji przez eksperta, którym może być osoba obsługująca urządzenia mechaniczne. Kontroler wyводу jest odpowiedzialny za poprawne zastosowanie wiedzy oraz za sposób wnioskowania. Interfejs jest częścią systemu odpowiedzialną za komunikację ze światem zewnętrznym (użytkownikiem), odpowiedzialnym za wprowadzanie danych do programu, jak również za wyprowadzanie wniosków na zewnątrz systemu. Rozróżnia się systemy ekspertowe:

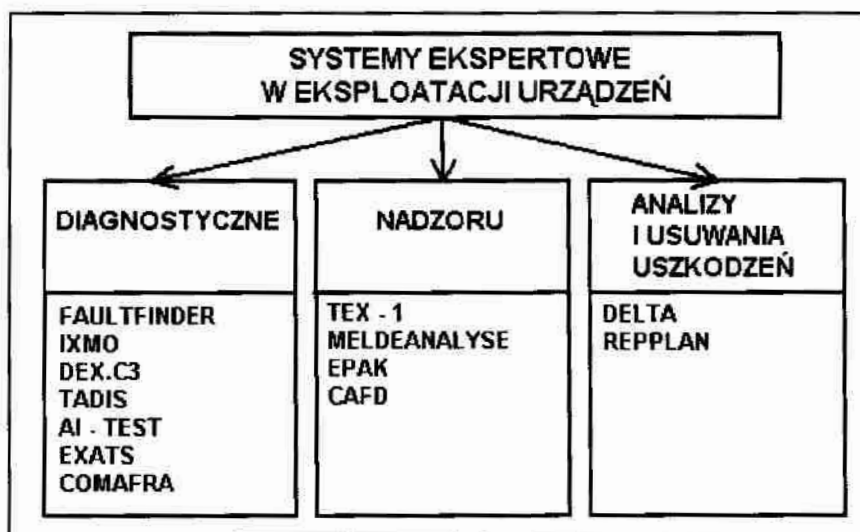
- a) regułowe,
- b) ramowe,
- c) sieci semantyczne,
- d) hybrydowe symboliczno – neuronowe.



Rys. 1.10: Budowa systemu ekspertowego.

Szczegółowy opis budowy, sposobów wnioskowania regułowych systemów ekspertowych wraz z przykładami przedstawiono w pracy [Nie2000]. Zagadnienie hybrydowych symboliczno-neuronowych systemów ekspertowych porusza w swojej pracy Białko [Bia2000].

Do niektórych systemów ekspertowych w eksploatacji urządzeń należy zaliczyć systemy przedstawione na rys. 1.11. Są to systemy diagnostyczne, systemy nadzoru oraz systemy analizy i usuwania uszkodzeń. Szczegółowy opis można znaleźć w pozycji [Paw1996].



Rys. 1.11: Przykładowe systemy ekspertowe zastosowane w eksploatacji urządzeń.

Zadaniem systemu FAULTFINDER jest pomoc użytkownikowi w rozpoznawaniu i lokalizacji uszkodzeń w skomplikowanych urządzeniach technicznych bez niepotrzebnego wzywania pomocy technicznej. System DEX.C3 (Diagnose-Expertensystem für automatische Getriebe vom Typ C3) służył do diagnostyki uszkodzeń przekładni samochodów ciężarowych. Podobne zadanie spełniał system IXMO, który służył do automatycznej diagnostyki niesprawności silników samochodów osobowych. Podczas prób silników dokonywano automatycznie pomiarów, a ich wyniki przekazywano do komputera jako dane o konkretnym egzemplarzu silnika. Był to system regulowy zawierający odpowiednie informacje z zakresu konstrukcji i eksploatacji silników spalinowych. Podobne zadanie miał spełniać system TADIS, który został opracowany do diagnostyki przekładni hydraulicznych. Jego zadaniem było wczesne wykrywanie niesprawności i diagnostyki szybkoobrotowych przekładni wykorzystywanych np. w elektrowniach. Do systemów sprawdzania i diagnozowania urządzeń elektronicznych zostały skonstruowane dwa systemy AI-TEST oraz EXATS.

Od początku lat 90-tych wprowadzane są w lotnictwie systemy do rejestracji, odczytu i analizy danych. Przykładem tego jest system COMAFRA zaprojektowany przez polską firmę ATM. System COMAFRA składa się z trzech głównych części: urządzeń do zbierania, gromadzenia danych do odczytu zarejestrowanych danych oraz oprogramowania do analizy zgromadzonego materiału. Podsystem do zbierania danych posiada budowę modułową tzn., że jego poszczególne elementy mogą występować osobno i inne elementy innych systemów mogą uzupełniać lub zastępować części podsystemu. Ciekawym systemem jest program THETYS opracowany przez Instytut Techniczny Wojsk Lotniczych.



Rys. 1.12: Systemy ekspertowe w technice lotniczej.

Wadą jego jest to, że oprogramowanie dostosowane jest tylko do wojskowych statków powietrznych. Jednym z początkowo zastosowanych w Polsce szkieletowych systemów ekspertowych był system ESTA (Expert System Shell for Text Animation). Wykorzystuje on oprogramowanie Prolog. Kowalkowski [Kow1995] opisuje jego zastosowanie w eksploatacji statków powietrznych MiG-29. Wykorzystanie komputerowo wspomaganego systemu projektowania naprawialności zaprezentowano w pracy

[Tar1999], gdzie przedstawiono system ekspertowy dotyczący dowolnej instalacji siłowni okrętowej – złożonego obiektu technicznego. Jedną z podstawowych instalacji okrętowych jest instalacja paliwowa, jest ona cały czas użytkowana podczas zasadniczej eksploatacji statku, podlega najczęstszym obsługom zarówno zapobiegawczym, jak i naprawczym, dlatego do budowy prototypu systemu doradczego wybrano elementy składowe takiej właśnie instalacji.

Szczegółową metodykę planowania procesu naprawy i formalnego jego opisu wykorzystując do tego celu język i metody systemów ekspertowych przedstawiono w [Paw1996]. Należy w tym miejscu wspomnieć o **opracowanym przez autora niniejszej pracy prototypie szkieletowego systemu ekspertowego** [Gło2001] przedstawionym na VIII Warsztatach PTSK w Gdańsku – Sobieszewie. W systemie tym zastosowano pakiet sztucznej inteligencji pod nazwą SPHINX 3.0. Na jego podstawie zbudowano bazę wiedzy oraz podsystem wnioskowania, który podaje przyczyny typowych niesprawności. Komputer-ekspert wyznacza rozwiązanie na podstawie wprowadzonej reprezentacji wiedzy według opracowanego algorytmu. Na podstawie tego algorytmu generuje on rozwiązanie, posługując się określonymi regułami i przepisami.

Aby opracować bardzo dobry system potrzebne jest współdziałanie wielu specjalistów z różnych dziedzin nauki, potrzebne jest również współdziałanie przemysłu, który dostarcza niezbędnych, wykonanych według najnowszych technologii urządzeń. Rozwój techniki komputerowej umożliwia takie podejście do zagadnienia.

Do systemów nadzoru zalicza się TEX-1, którego zadaniem było nadzorowanie pracy reaktora jądrowego. Co warto zaznaczyć, jest to system pracujący w czasie rzeczywistym. Zadaniem systemu MELDEANALYSE było nadzorowanie procesów w elektrowni konwencjonalnej. Chodziło o zredukowanie ilości informacji docierających do personelu, lokalizację i wyjaśnianie przyczyn zakłóceń w pracy. Do kontrolowania i sterowania jakością produkcji papieru został opracowany system EPAK (Expertensystem zur Sicherung der Papierqualität). W celu nadzorowania pracy sprężarki osiowej opracowano w USA system bazujący na technice sieci neuronowych.

Do planowania procesów remontów zostały stworzone m.in. DELTA (Diesel-Electric Locomotive Troubleshooting Aid) oraz REPPLAN (Reparaturplaner). Pierwszy z nich służył do diagnostyki lokomotyw elektryczno – spalinowych, natomiast zadaniem drugiego było rozpoznawanie i lokalizacja uszkodzeń.

Na zakończenie tego podrozdziału należy wspomnieć o opracowanym kompleksowym systemie diagnostycznym DIA - K15 o cechach eksperckich. Służy on do monitorowania stanu technicznego silnika K-15 w samolocie I-22 Iryda. Powyższy system składa się m.in. z czujników i sygnalizatorów, pomiarowych urządzeń standardowych, bazy danych, *procedur objaśniania i wnioskowania* [Kud1999]. Niestety, w związku z katastrofami przerwano prace nad wprowadzeniem systemu do eksploatacji.

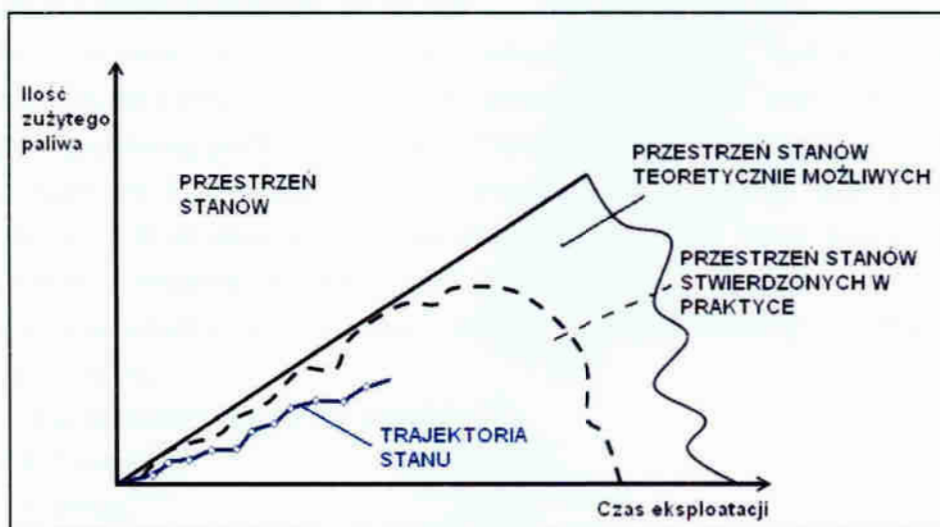
Przedstawione powyższe przykłady świadczą o tym jak ważne miejsce w eksploatacji maszyn zajmują systemy ekspertowe.

1.4. Proces użytkowania statków powietrznych


Urządzenia mechaniczne znajdują się w każdej chwili w pewnym określonym stanie, a sekwencje czasowe tych stanów rozpatruje się jako czas istnienia urządzeń. W celu kwantyfikacji wiedzy o procesie eksploatacji urządzenia i aktualnym jego stanie należy wprowadzić pojęcia trajektorii i przestrzeni stanów [Paw1996]. Trajektorią określa się funkcję przyporządkowującą chronom kalendarza odpowiednie stany wyróżnione systemu. W przypadku układów wielowymiarowych trajektoria to ciąg wektorów stanów. Każdy wektor stanu należy rozpatrywać jako współrzędne punktu w pewnej przestrzeni, a trajektorię wektora stanów – jako ruch punktu w tej przestrzeni. Wymiar przestrzeni stanu jest równy liczbie składowych wektora stanu. W przypadku eksploatowanych statków powietrznych wektor ten może posiadać następujące składowe:

- a) wiek,
- b) liczba godzin spędzonych w powietrzu,
- c) sposób eksploatacji, taki jak np. walki powietrzne, szturmowanie celów naziemnych, loty po trasach, loty na przechwytywanie celów powietrznych, loty do strefy na pilotaż, loty po systemie, kręgu nadlotniskowym itp.,
- d) sposób przechowywania (hangarowanie),
- e) obciążenie, np. loty z dużymi przeciążeniami, loty na maksymalnym zakresie pracy silnika – z dopalaniem paliwa,
- f) konserwacja i obsługa urządzenia, zgodna lub niezgodna z wymaganiami technicznymi.

Niektóre ze składowych wektora stanu przyjmują wartości dyskretne, np. sposób eksploatacji, inne przyjmują wartości ciągłe, jak np. wiek, liczba godzin spędzonych w powietrzu. Na rys. 1.13 przedstawiono przykład dwuwymiarowej przestrzeni stanów eksploatowanego urządzenia, gdzie jednym z wymiarów jest czas eksploatacji, natomiast drugim ilość zużytego paliwa przez samolot.



Rys. 1.13: Dwuwymiarowa przestrzeń stanów eksploatowanego urządzenia [Paw1996].



Rys. 1.14: Wielowymiarowa przestrzeń stanów.

Na rys. 1.14 przedstawiono przykład wielowymiarowej przestrzeni stanów użytkowania statku powietrznego, gdzie w zależności od sposobu eksploatacji, liczby godzin spędzonych w powietrzu oraz od liczby wykonanych lotów samolot znajduje się w określonym punkcie w przestrzeni stanów. Pierwsze pięć punktów rejestruje przebieg eksploatacji samolotu, jako lotów do stref w celu wykonania figur pilotażu. Umożliwią one nauczenie, bądź przypomnienie techniki wykonywania określonych manewrów niezbędnych do zastosowania w walce powietrznej. Od szóstego punktu samolot jest wykorzystywany do walk powietrznych, natomiast od jedenastego do atakowania celów naziemnych. Następnie przejście z powrotem do płaszczyzny „walki powietrzne” i dalsza eksploatacja. Proces eksploatacji statku powietrznego, należy więc traktować jako przechodzenie z jednej przestrzeni do drugiej.

Trajektorie stanów każdego statku powietrznego jest inna. Jest to uzależnione od rodzaju misji. Młodzi piloci z reguły nie rozpoczynają lotów od zastosowania bojowego. Na początku opanowują pilotaż od lotu po prostej, poprawnym wykonywaniu startu, bądź lądowania. Dotyczy to również lotnictwa transportowego, którego przestrzenie stanów będą odmienne. Jest to spowodowane innym rodzajem misji, które wykonują samoloty lotnictwa transportowego niż samoloty myśliwskie lub wielozadaniowe.

Każdy przedstawiony powyżej stan – misję statku powietrznego można rozłożyć na podstany, którymi są:

- a) uruchomienie silnika lub silników,
- b) kołowanie,
- c) rozbieg,
- d) start,

- e) wznoszenie do nakazanej wysokości,
- f) lot do miejsca wykonania zadania,
- g) proces wykonywania zadania,
- h) powrót na lotnisko lądowania,
- i) etap lądowania,
- j) dobieg,
- k) kołowanie,
- l) wyłączenie silnika lub silników.

Niektóre podstany mogą być podobne do siebie w różnych misjach, jak np. uruchomienie silnika, kołowanie, lądowanie i wyłączenie silnika. Przebywanie statku powietrznego w każdym ze stanów ma zasadniczy wpływ na wielkość potencjału eksploatacyjnego.

1.5. Własności otoczenia i wpływ warunków atmosferycznych na proces eksploatacji

Każde urządzenie mechaniczne jest eksploatowane w określonych warunkach otoczenia, które ma zasadniczy wpływ na jego poprawną i niezawodną pracę. Niewłaściwe parametry otoczenia mogą powodować szybsze zużywanie się urządzeń, ponadto urządzenia mogą ulegać uszkodzeniom. Otoczenie, z punktu widzenia niezawodności nazywane inaczej zmiennymi warunkami fizycznymi, powoduje zmianę wartości cech mierzalnych urządzenia poza granice ich tolerancji lub zmienia stan cech niemierzalnych, powodując nie spełnienie wymagań przez użytkownika. W otoczeniu występują czynniki, które w mniejszym lub większym stopniu mogą mieć wpływ na pracę urządzenia mechanicznego. Istotną cechą otoczenia jest to, że występuje w nim ogromne bogactwo zdarzeń losowych, którymi rządzą prawa rozkładu prawdopodobieństwa wystąpienia określonego zdarzenia, a które są uzależnione m.in. od:

- a) charakteru pracy urządzenia,
- b) rodzaju środowiska w jakim urządzenie pracuje.


Czynniki występujące w otoczeniu można podzielić na dwie zasadnicze klasy: uwarunkowane i uwarunkowane funkcjonowaniem urządzenia mechanicznego [Okr1980]. Czynniki uwarunkowane oddziałują na urządzenie tylko w trakcie wykonywania przezeń swoich funkcji, natomiast uwarunkowane oddziałują na urządzenie w wyniku samej swojej obecności w otoczeniu, nawet wtedy, gdy urządzenie swoich funkcji nie wykonuje. Ponadto praca urządzenia powoduje generowanie czynników wymuszających, które według [Waż1990] można podzielić na:

- a) wewnętrzne – robocze (working stresses),
- b) zewnętrzne (environmental stresses).

Czynniki zewnętrzne charakteryzują otoczenie obiektu i są przez nie generowane, natomiast czynnikami wewnętrznymi są wszelkiego rodzaju przegrzania lub zmęczenia konstrukcji, spowodowane przez zjawiska zachodzące w urządzeniach zespołów, bądź układów przetwarzających energię. Czynniki wewnętrznymi mogą być procesy

mechaniczne, elektryczne i ciepłe. W grupie czynników zewnętrznych wyróżnia się klimatyczne, przyrodnicze, chemiczne, *użytkowanie* oraz *obsługiwanie*.

Rodzaje sił oddziaływujących na statek powietrzny podczas lotu przedstawiono na rysunku 1.15. Są to siły występujące podczas funkcjonowania urządzenia.



Rys. 1.15: Siły oddziałujące na samolot podczas lotu.

Każdy rodzaj sił wywiera istotny wpływ na proces eksploatacji urządzeń. Statki powietrzne, ich zespoły, urządzenia, agregaty oraz elementy pracują w specjalnych warunkach, czego przyczyną jest różnorodność czynników działających na statek powietrzny w czasie i w przestrzeni. W przypadku statków powietrznych transportowych, np. An-2 z silnikiem tłokowym, siły bezwładności mają zasadniczy wpływ na niezawodność funkcjonowania układu paliwowego. Przypadek awarii, która była spowodowana przez siły bezwładności został opisany w [Lew1993/2]. Pewne warunki lotu mogą powodować zaburzenia w pracy silnika, pomimo stosowania pomp paliwowych, które przetłaczają paliwo z komór zbiorników do silnika. Jest to związane z tym, że samolot podczas lotu może zajmować różne położenie przestrzenne. Awarie mogą dotyczyć szczególnie instalacji paliwowych typu otwartego, tzn., gdy zbiorniki paliwa i gaźnik silnika mają połączenie z atmosferą. A zatem podczas różnych faz lotu pompa paliwa może zajmować różne położenie względem swobodnej powierzchni paliwa w zbiornikach a mianowicie:

- a) może znajdować się poniżej powierzchni paliwa w zbiornikach – najkorzystniejsze położenie dla pracy pompy i niezawodnego napełniania gaźnika,
- b) może być na jednym poziomie z paliwem w zbiorniku,
- c) może znajdować się powyżej poziomu paliwa w zbiorniku (niektóre fazy lotu).

Najkorzystniejsze położenie pompy jest w przypadku a) oraz b). W przypadku c) mogą wystąpić przerwy w pracy silnika.

Siły dyspozycyjne nazywa się również siłami oporów szkodliwych. Są to siły tarcia, które powstają w parach kinematycznych oraz siły ośrodka, w którym odbywa się ruch, jak również siły tarcia wewnętrznego w materiale.

W przypadku statków powietrznych destrukcyjne są wibracje oraz drgania spowodowane m.in. pracą zespołu napędowego. Są to zwykle drgania o dużej częstotliwości. Mogą być spowodowane niewyważeniem wirujących elementów i zespołów, błędami w ich osiowaniu, luzami w przegubach oraz miejscach utwierdzenia, jak również pulsacjami ciśnienia w trakcie przepływowym. Występujące drgania konstrukcji zmieniają obraz obciążenia elementów. Wyczerpujący opis problemu przedstawiony został w pracy [Lew1993/2]. Podczas lotu samolotu drgania elementów płatowca powodowane są przez siły aerodynamiczne, porywy wiatru. Amplituda drgań zależy od stopnia turbulencji powietrza i prędkości lotu. Drgania aerodynamiczne elementów płatowca charakteryzują się małymi częstotliwościami rzędu 2-15 Hz. Przy prędkości lotu odpowiadających liczbie Macha $Ma = 0,9 - 1,05$ wzrasta intensywność zaburzeń w opływie płatowca. W tym miejscu należy wspomnieć o drganiach występujących podczas kołowania, startu i lądowania spowodowanych przez siły reakcji ziemi. Charakteryzują się niewielkimi częstotliwościami od 1-3Hz do 20-30Hz i dużymi amplitudami. Częstotliwość drgań oddzielnych elementów statku powietrznego może osiągać poziom 200-5000Hz. w wyniku tych drgań przyspieszenia na końcach skrzydła są 2 – 3 razy większe, a ogonowej części kadłuba 2 razy większe niż w środku ciężkości samolotu.

W wyniku spalania paliwa w silniku nagrzewają się jego elementy. Gazy spalinowe mają wysoką temperaturę, szczególnie na zakresie dopalania. Temperatura gazów za turbiną dochodzi do około 1000°C. W wyniku promieniowania ciepła z nagranych elementów silnika, w jego gondoli może występować temperatura 100-120°C, szczególnie w pobliżu komór spalania silnika i dopalacza. W przypadku lotów naddźwiękowych następuje nagrzewanie płatowca spowodowane tarciem otaczającego powietrza o powierzchnię płatowca. Początkowo rozkład temperatur w konstrukcji jest nierównomierny, lecz po pewnym czasie wyrównuje się. Temperaturę powierzchni płatowca w miejscu wyhamowania strumienia powietrza wyraża się zależnością:

$$T^* = T_H(1 + 0,18Ma^2), \quad (1.1)$$

gdzie: T_H [°K] - temperatura powietrza na wysokości H,
 Ma - liczba Macha.

Przy temperaturze otaczającego 270°K i prędkości 1,5Ma, powierzchnia płatowca zgodnie z zależnością (1.1) może osiągnąć temperaturę 379,35°K ($\approx 100^\circ\text{C}$).

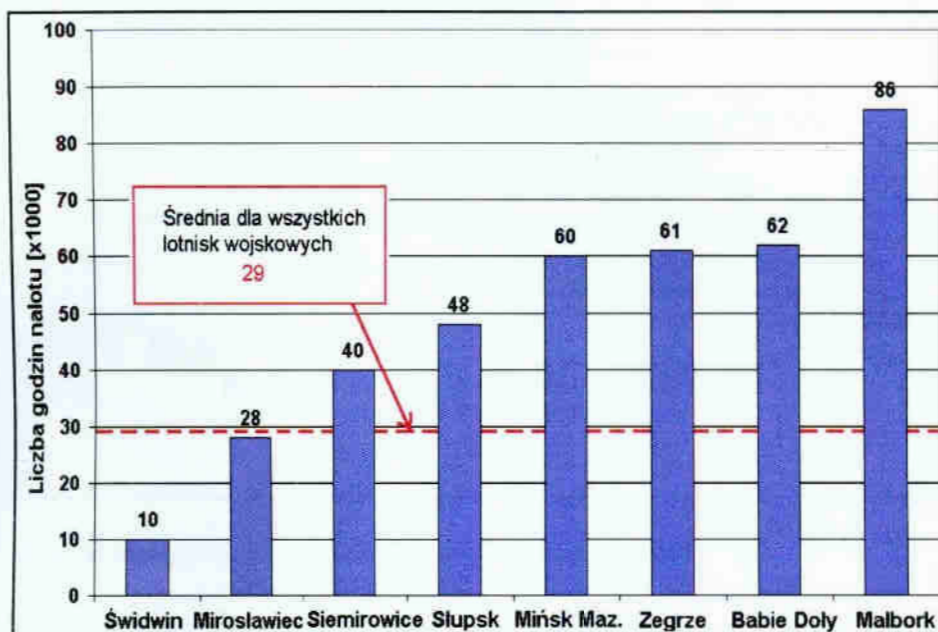
Agregaty instalacji paliwowych, hydraulicznych, olejowych oraz powietrznych w zależności od miejsca zamocowania na statku powietrznym, pracują w zakresie temperatur od około -20°C do około 300°C . Hydrauliczne wciągniki zwieraczy dyszy osiągają temperatury około 400°C . Jest to spowodowane opływającym strumieniem spalin. Temperatura cieczy roboczych osiąga wówczas wartość 250°C w wyniku przetłaczania oraz podgrzewania ciepłem z silnika. Największym problemem w takim przypadku jest uszczelnienie instalacji. W niektórych sytuacjach (przy dużym gradiencie temperatury) może dojść do rozszczelnienia instalacji. Zbyt wysoka temperatura powoduje wytrącanie związków smolistych osiadających na agregatach. Ich obecność w instalacjach jest niekorzystna, ponieważ powoduje zatykanie filtrów, dysz regulacyjnych itp. Ponadto wysoka temperatura może intensyfikować niekorzystne procesy chemiczne w eksploatowanych cieczach.

Warunki klimatyczne zaliczono do zewnętrznych czynników z tego powodu, że np. statki powietrzne są eksploatowane w różnych warunkach klimatycznych (ciśnienie w atmosferze wzorcowej zmienia się w zakresie od 0,095 do 0,1040 MPa, temperatura powietrza w zakresie -60°C do $+50^{\circ}\text{C}$, prędkość wiatru – szczególnie prądy strumieniowe na dużych wysokościach osiągają wartości rzędu 40 m/s). Niskie temperatury mają negatywny wpływ na pracę instalacji paliwowych i olejowych oraz układów ich regulacji. Współczesna konstrukcja i możliwości lotno – techniczne wojskowych statków powietrznych umożliwiają osiągnięcie wysokości 10000 metrów w czasie od 1 do 2 minut. Powoduje to gwałtowną zmianę warunków atmosferycznych, np. zmianę temperatury od $+25^{\circ}\text{C}$ do -50°C . Do czynników klimatycznych należy zaliczyć również wilgotność otoczenia. Duża wilgotność (rzędu 90%) powoduje przyspieszoną korozję słabo zabezpieczonych elementów. Dotyczy to zwłaszcza statków powietrznych eksploatowanych w umiarkowanym klimacie. Statki powietrzne, które są eksploatowane w klimacie śródziemnomorskim, niekoniecznie muszą posiadać swoje właściwości w klimacie umiarkowanym. Niższe temperatury i duża wilgotność wymusi na użytkowniku zastosowanie innych form eksploatacji bądź wprowadzenie ograniczeń. Niekiedy użytkownicy nie zdają sobie sprawy jak ważną rolę w eksploatacji odgrywają czynniki klimatyczne, które mogą powodować występowanie częstszych awarii, a w końcowym efekcie skrócenie czasu eksploatacji urządzeń. Statki powietrzne, które nie były przystosowane do eksploatowania w polskich warunkach klimatycznych mogą nie spełnić oczekiwań użytkownika, pomimo tego, że konstruktorzy podczas projektowania przewidzieli możliwość eksploatacji w innych warunkach. Należy to również brać pod uwagę, a w wielu przypadkach się o tym zapomina.

Bardzo niekorzystny wpływ na pracę urządzeń mechanicznych mają czynniki przyrodnicze lub biologiczne. Dotyczy to szczególnie niezawodności pracy silników statków powietrznych.

Zassanie do silnika powietrza silnie zanieczyszczonego tzw. ciałami obcymi, w rodzaju piasku, okruchów betonu może spowodować uszkodzenia erozyjne, wgniecenia,

skaleczenia lub odkształcenia łopatek sprężarki uniemożliwiającej dalszą poprawną pracę silnika. Przyczyną jest nierównomierna i zabrudzona płaszczyzna postoju, dróg kołowania lub drogi startowej. Jest to szczególnie niebezpieczne w przypadku zderzenia z lecącym stadem ptaków. Zderzenia statków powietrznych z ptakami w przeliczeniu na 100000 godzin nalotu przedstawiono na rysunku 1.16. Na lotnisku w Świdwinie występuje najmniej zderzeń z ptakami (10 na 100000 godzin nalotu), natomiast w Malborku prawie osiem razy więcej.



Rys. 1.16: Zderzenia samolotów z ptakami nad lotniskami od 1984 do 1994 roku na 100000 h nalotu [Bar1994].

Najbardziej niebezpiecznym momentem jest start i lądowanie samolotu, a skupiska ptaków bardzo często można spotkać nad płaszczyzną lotnisk. Jest to problem, z którym boryka się większość użytkowników statków powietrznych, nie tylko cywilnych. Przeciwdziałając temu, stosuje się odstraszacze wydające huk, co pewien okres czasu, ponadto specjalnie trenowane sokoły. Powyższy problem występuje szczególnie wiosną oraz jesienią i jest związany z migracją ptaków.

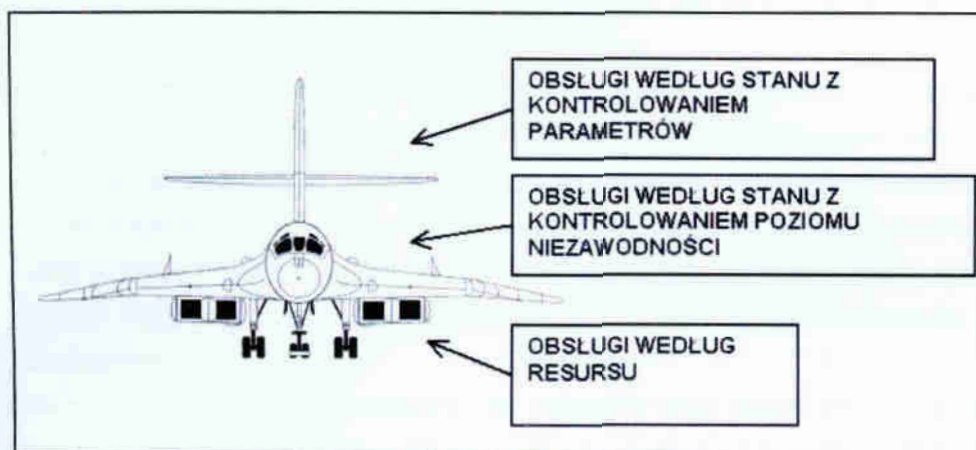
Należy w tym miejscu wspomnieć o czynnikach starzeniowych. Utlenianie materiałów, rozkład substancji oraz korozja metali wpływa również destrukcyjnie na eksploatowane urządzenia.

Do istotnych czynników zalicza się zasady obsługiwanie, które opisane zostaną w następnym podrozdziale.

1.6. Zasady obsługiwanie w technice lotniczej

Obsługiwanie techniczne urządzeń mechanicznych jest częścią procesu jego eksploatacji. Każdemu użytkownikowi urządzeń mechanicznych zależy na zmniejszeniu

kosztów eksploatacji oraz kosztów dotyczących obsługi. Obniżenie kosztów obsługi można dokonać poprzez uproszczenie lub zastosowanie nowych konstrukcji. Danilecki [Dan1995] wprowadza pojęcie technologiczności użytkowej, czyli przystosowanie urządzenia do łatwej obsługi (maintainability). W obsługach pierwszych konstrukcji statków powietrznych stosowano tak zwane prewencyjne obsługi wszystkich elementów samolotów (hard – time). Zgodnie z harmonogramem ustalonym przez konstruktora (producenta) dokonywano kompletnego demontażu każdego elementu statku powietrznego. Wiązało się to z olbrzymimi kosztami.



Rys. 1.17: Metody obsługi technicznego statków powietrznych.

Wraz z postępem technologicznym zaczęto stosować tak zwane przeglądy blokowe (block overhaul concept). Miały one na celu zmniejszenie kosztów obsługi. Każdy blok prac był wykonywany z zachowaniem ściśle określonej okresowości. Pozwoliło to na wyeliminowanie obsługi elementów, w których nie występowały awarie, bądź zdarzały się sporadycznie. Najbardziej korzystne było stworzenie obsługi zgodnie z koncepcją tak zwanego stanu (on-condition), w latach pięćdziesiątych na zachodzie. W odniesieniu do niektórych elementów ustalono metody i sposób prób funkcjonalnych wykonywanych regularnie na statkach powietrznych. Umożliwiło to zminimalizowanie kosztów i zwiększenie możliwości eksploatacyjnych. Rodzaje obsługi przedstawiono na rys. 1.17.

Metoda według resursu była i jest stosowana w konstrukcjach statków powietrznych byłego Związku Radzieckiego. Należy w tym momencie wyjaśnić pojęcie resursu, który to jest czasem pracy urządzenia mierzonym najczęściej liczbą godzin pracy od momentu rozpoczęcia użytkowania aż do chwili osiągnięcia takiego stanu technicznego (przeciętnego stanu zużycia), który ze względu na zmniejszenie sprawności, poziomu niezawodności, bądź bezpieczeństwa eksploatacji kwalifikuje je do naprawy głównej lub wycofania z eksploatacji. Słowo resurs pochodzi z języka francuskiego ressource lub angielskiego resource i oznacza „ustalany doświadczalnie i teoretycznie okres pracy sprzętu, w czasie którego zagwarantowane jest bezpieczeństwo i sprawność eksploatacji.

Jest to również miara zdolności użytkowej urządzenia wyrażona w określonych jednostkach”.

W systemie obsługi według resursu, wszystkie urządzenia eksploatowane w czasie ściśle określonym przez producenta są kierowane do naprawy lub wycofywane z eksploatacji po przepracowaniu określonego czasu. Resurs wyznacza się tak, aby spełnione były następujące warunki [Lew2003]:

- a) *spadek sprawności pod koniec użytkowania, w ramach wyznaczonego resursu, nie może przekraczać wartości wyznaczonej przez konstruktora (producenta),*
- b) *poziom bezpieczeństwa w czasie całego okresu eksploatacji powinien pozostać nie zmieniony,*
- c) *koszt naprawy zapewniającej przywrócenie właściwej sprawności urządzenia nie może przekraczać określonej, ekonomicznie uzasadnionej części kosztu nowego urządzenia. Wartość ta ustalona jest indywidualnie dla każdego typu urządzenia na podstawie analizy ekonomicznej (uważa się, że nie powinien przekraczać 30 – 50% wartości nowego urządzenia). W uzasadnionych przypadkach, dokonuje się jednak naprawy urządzenia. Może to być związane z zakończeniem produkcji elementów.*

Wyróżnia się resurs międzyremontowy - po naprawie oraz resurs techniczny nazywany również trwałością techniczną. Pierwszy z nich jest liczony jako czas pracy od chwili rozpoczęcia użytkowania urządzenia do pierwszej naprawy lub po naprawie do kolejnej naprawy, uwarunkowanej stanem technicznym, zdefiniowanym jak dla resursu. Każdy kolejny resurs po naprawie może być równy lub krótszy od poprzedniego. Resurs techniczny jest sumą okresów resursowych, ograniczoną takim stanem technicznym, czyli stopniem zużycia urządzenia, przy którym:

- a) *spadek sprawności osiąga wartość graniczną lub nie może utrzymać na wymaganym poziomie niezawodności i bezpieczeństwa eksploatacji, pomimo zabiegów technologicznych,*
- b) *koszt naprawy przywracającej wyżej podane własności przekraczałby ekonomicznie uzasadnioną wartość.*

Według [Dan1995] zaobserwowano, że w większości przypadków obsługi według resursów, czyli naprawy i wymiany elementów po ściśle określonym czasie, **nie były efektywnym sposobem utrzymania założonego poziomu niezawodności**. Dotyczy to szczególnie uszkodzeń lokalnych pokryć powłokowych statków powietrznych. *Przeprowadzono analizę bezpiecznych okresów użytkowania powłoki ciągłej i sąsiadujących z nią połączeń nitowych w dolnym pokryciu skrzydła samolotu AN-24.* Profesor Danilecki cytując metodę podaną przez Lundberga i Eggwertza, rozwiniętą przez Minera, wprowadza pojęcie ogólnego zużycia zmęczeniowego, które jest wyrażone jako [Dan1982/1]:

$$D = \sum_{i=1}^m \left(\frac{n}{N} \right)_i, \quad (1.2)$$

gdzie: n - jest liczbą zmian obciążeń przyłożoną do konstrukcji w określonym stanie naprężeń zmiennych,

N - jest liczbą zmian tych obciążeń potrzebnych do zniszczenia w tych samych warunkach,

m - jest liczbą poziomów naprężeń.

Podczas badań *dowodząco doświadczalnie*, że wartości sum stosunków n/N odpowiadające zniszczeniu zmęczeniowemu są zarówno większe, jak i mniejsze od 1, a w przypadku występowania pojedynczych obciążeń wprowadzających naprężenia własne mogą prowadzić do znacznych odchyśleń od uznanej przez Minera za podstawową wartość 1. W pracy zasygnalizowano konieczność wprowadzenia arbitralnych współczynników korygujących, sprawdzanych w praktyce podczas użytkowania statków powietrznych. Z dalszej analizy pracy wynika, że bezwymiarowy bezpieczny okres użytkowania statku powietrznego można wyrazić przy pomocy zależności:

$$R = \frac{1}{D}, \quad (1.3)$$

i jest on odniesiony do bazy określonej jako łączna długość przelotów lub czas lotu. Bezpieczny okres użytkowania można wyznaczyć również w zależności od średniej prędkości operacyjnej samolotu v , km/h, jeśli obliczono całkowite zużycie zmęczeniowe konstrukcji na bazie L_0 kilometrów widma obciążeń od podmuchów:

$$t = \frac{L_0}{D \cdot v} = BOU, \quad (1.4)$$

gdzie: L_0 - liczba km, podstawowa dla przyjętego widma obciążeń, które jest uzależnione od typu statku powietrznego.

W przypadku statków powietrznych rozkład czasu pracy do uszkodzenia jest rozkładem wykładniczym, co powoduje, że nie ma związku między czasem eksploatacji statku powietrznego a prawdopodobieństwem powstania uszkodzenia poszczególnych jego elementów. Planowane naprawy lub wymiana elementów nie wpływa na jego charakterystyki niezawodnościowe.

Metoda obsługiwanego według stanu z kontrolowaniem parametrów, polega na ciągłym lub okresowym diagnozowaniu i prognozowaniu stanu technicznego. Przy zastosowaniu tej metody można wyeliminować planowane naprawy główne. W takim przypadku ustala się docelową okresowość (resurs), która ograniczona jest niezawodnością najbardziej niezawodnego elementu w urządzeniu. Podstawą tej metody jest diagnozowanie, jako źródło uzyskiwania niezbędnych i wiarygodnych informacji o stanie technicznym urządzenia.

Metoda obsługiwanego według stanu z kontrolowaniem poziomu niezawodności polega na eksploatacji zbioru elementów jednego typu, lecz bez ograniczenia ich okresowości

międynaprawczej, przy jednoczesnym wykonywaniu obsług, aż do chwili, gdy nie zostanie przekroczona granica dopuszczalnego poziomu ich niezawodności. Należy jednak zaznaczyć, że trudno jest określić granicę dopuszczalnego poziomu niezawodności, szczególnie, jeśli chodzi o życie osób eksploatujących urządzenie.

W eksploatacji urządzeń stosowana jest planowo – zapobiegawcza strategia obsługiwanie urządzeń. Stwarza ona warunki właściwego sterowania eksploatacją urządzeń. W przypadku statków powietrznych okres do przeglądu wyrażony jest liczbą godzin spędzonych w powietrzu. Stanowi to podstawę do planowania obsług. Niestety okres czasu nie jest związany ze sposobem eksploatacji jak loty na walki powietrzne, na szturmowanie celów naziemnych, itp. Zadaniem planowania obsług statków powietrznych jest optymalizacja struktury statków powietrznych i regularność przeprowadzenia prac w celu zapewnienia wymaganego poziomu eksploatacyjnej niezawodności i bezpieczeństwa osób eksploatujących samolot. Ma to również znaczenie ściśle ekonomiczne. Reasumując, obsługi statków powietrznych mają na celu:

- a) utrzymanie sprzętu w stałej sprawności i gotowości do wykonywania zadań a w przypadku lotnictwa wojskowego do wykonywania zadań bojowych w warunkach zmiennej sytuacji bojowej,
- b) przygotowanie statków powietrznych do wykonywania lotów w każdych warunkach atmosferycznych, w dzień i w nocy,
- c) utrzymanie wysokiej niezawodności statków powietrznych,
- d) naprawę uszkodzeń eksploatacyjnych, możliwie w najkrótszym okresie czasu.

W tym miejscu należy wspomnieć o oddziaływaniu operatora na statek powietrzny. Niewłaściwe postępowanie, niezgodne z założeniami, przy użyciu niewłaściwych narzędzi może prowadzić do uszkodzeń sprzętu. Przykładem tego może być dokręcenie śruby z nieprawidłową wartością momentu lub błędna analiza danych pomiarowych. W pierwszym przypadku może dojść w czasie lotu do poluzowania połączenia, natomiast w drugim przypadku zakwalifikowanie niesprawnego zespołu lub agregatu jako sprawny. Oba przypadki mogą doprowadzić do katastrofy.

Lemski [Lem2001] proces eksploatacji samolotu dzieli na cztery główne etapy (tabela 1.1). Pierwszy etap jest okresem początkowym, liczonym od momentu wejścia statku do eksploatacji. Trwa on około 1 roku i odpowiada tzw. gwarancyjnemu okresowi eksploatacji statków, w którym prace zmierzające do podtrzymania i odtwarzania stanu technicznego są przeprowadzane według systemu planowo – gwarancyjnego. W powyższym okresie eksploatacji brak jest usystematyzowanych informacji o użytkowaniu technicznym i niezawodności urządzenia. Dane te można uzyskać jedynie od producenta, bądź na podstawie obliczeń projektowych. W tym okresie do planowania obsług zastosowany jest model deterministyczny „bez przeszłości” – przy wykorzystaniu informacji tylko statystycznych, od producenta o charakterze zmian występujących w urządzeniu.

Drugi etap jest okresem zbierania i gromadzenia informacji o użytkowanym urządzeniu. Dane uzyskane od producenta zastępuje się danymi rzeczywistymi. W związku z tym, że okres czasu eksploatacji jest zbyt krótki stosuje się w tym przypadku również model deterministyczny „bez przeszłości”.

Tabela 1.1: Etapy eksploatacji statku powietrznego.

Etap eksploatacji statku powietrznego	System planowania obsługi	Model planowania	Cel planowania
początkowy (≈1 roku)	planowo – gwarancyjny	deterministyczny „bez przeszłości”	zabezpieczenie gwarancyjne
wstępny (do ≈4 lat)	planowo – zapobiegawczy	deterministyczny „bez przeszłości”	optymalizacja
zasadniczy (podstawowy) (do ≈20 lat)	planowo – zapobiegawczy	deterministyczny „z przeszłością”	optymalizacja obsługi technicznych
końcowy (powyżej 20 lat)	podtrzymujący	deterministyczny „z przeszłością”	minimalizacja obsługi technicznych

Trzeci etap jest najdłuższy pod względem czasu trwania i najważniejszy z punktu widzenia użytkownika. Przed przejściem do powyższego etapu powinny być wykonane badania diagnostyczne oraz kontrola stanu technicznego. Pozwoli to na określenie zmian stanu technicznego statku powietrznego w przeszłości. Dlatego celowe wydaje się zastosowanie w tym okresie modelu deterministycznego „z przeszłością”. Jedynym problemem są obsługi, które zostały ustalone przez producenta (konstruktora) i użytkownik nie może przekraczać ograniczeń czasowych z tym związanych. Dotyczy to obsługi według resursu. Większość eksploatowanych statków powietrznych podlega temu rodzajowi obsługi. Użytkownik może jedynie wnioskować do konstruktora o zmianę terminów obsługi.

Ostatni etap odpowiada końcowemu okresowi eksploatacji. Użytkownik przechodzi na system podtrzymywania poziomu stanu technicznego. W tym okresie wykonywane są prace remontowo – odtwarzające. Wymaga to znajomości zmian w obiekcie technicznym. Wykorzystuje się do tego zgromadzone dane podczas okresu normalnej (głównej) eksploatacji. Dlatego na tym etapie wykorzystuje się również model deterministyczny „z przeszłością”.

W przypadku statków powietrznych wyróżnia się następujące rodzaje obsługi :

a) w dniu użytkowania:

- przedlotowa,
- przedstartowa,
- między wylotami,
- polotowa;

b) okresowe:

- po 25 godzinach lotu,
- po 50 godzinach lotu,

- po 100 godzinach lotu,
- po 200 godzinach lotu;
- c) konserwacyjne - związane z okresem postoju – bez wykonywania lotów:
 - po 10 dniach postoju,
 - po 15 dniach postoju,
 - po 30 dniach postoju;
- d) okresowe (związane z porą roku, zmianą płynów w instalacjach):
 - wiosenno – letnie,
 - jesienno – zimowe;
- e) konserwacyjne.

Każda obsługa zawiera od kilkudziesięciu do kilkuset czynności, które powinny zostać wykonane w odpowiedniej kolejności i w odpowiednim okresie czasu. Są one zawarte w Zestawach Obsług Technicznych i dotyczą konkretnego typu statku powietrznego.

Inny podział obsługi (SP) zaprezentowany został w [Jaź1989]. Według autorów wyróżnia się następujące rodzaje obsługi:

- c) zaopatrywanie,
- d) kontrola stanu,
- e) czynności profilaktyczne,
- f) naprawy.

Celem zaopatrywania jest uzupełnienie paliwa, energii elektrycznej, gazów i cieczy roboczych na statku powietrznym. Kontrola stanu jest przeprowadzana podczas obsługi okresowych, w czasie których statek powietrzny jest poddawany czynnościom profilaktycznym mającym za zadanie przystosowanie go do dalszego wykonywania lotów. Naprawy dzieli się na bieżące i profilaktyczne oraz planowe – umożliwiające odtworzenie zasobu pracy (SP) oraz jego zespołów i podzespołów.

1.7. Intensywność użytkowania i podatność obsługi


Wykonanie lotu przez statek powietrzny jest związane ze specyficznym miernikiem ilości wykonanej pracy. Jak wspomniano w podrozdziale 1.4 w przypadku statku powietrznego może to być liczba spędzonych godzin w powietrzu, bądź wiek. Okręglicki [Okr1980] wprowadza pojęcie miernika intensywności pracy λ , określającego ilość pracy poszczególnych zespołów, podzespołów lub agregatów statku powietrznego na jednostkę czasu (godzinę, dobę, miesiąc, rok). Intensywność pracy statku powietrznego nazywana jest powszechnie intensywnością użytkowania. Można wyrazić ją przez: prędkość lotu w kilometrach na godzinę, liczbą godzin nalotu na dobę, miesiąc itp., w przypadku lotnictwa transportowego w wielkości przewiezionego ładunku na jednostkę czasu, w kilogramach na godzinę lotu, oznaczany przez ΔL . Intensywność użytkowania λ należy rozpatrywać jako wartość średnią w przedziale czasu podawanym w mianowniku wyrażenia określającego jednostkę miary intensywności. W takim przypadku wartość średnia

intensywności użytkowania λ_t w przedziale czasu pracy Δt statku powietrznego określona jest następująco:

$$\lambda_t = \frac{\Delta L(t, t + \Delta t)}{\Delta t}. \quad (1.5)$$

Na rysunku 1.18 przedstawione zostały typowe przebiegi funkcji chwilowej intensywności użytkowania $\lambda(t)$ oraz uśrednionej intensywności użytkowania λ_t dla statku powietrznego wykonującego lot w czasie t .

Dla każdego elementu samolotu wyznacza się taką ilość pracy $\Delta L_p = Z$, zwaną resem, po której wymaga on określonego rodzaju obsługi technicznej, lub wymiany na nowy. Dla całego statku powietrznego może to być resem do kolejnego zatankowania, do kolejnej obsługi okresowej, do kolejnej naprawy i jest wyrażony w godzinach nalotu. Wartość resursu niektórych urządzeń zamontowanych na statku powietrznym można zmieniać w pewnych granicach. Dokonuje się tego poprzez zmianę konstrukcji i technologii urządzenia. Co więcej, w intencji każdego konstruktora jest skonstruowanie takiego urządzenia mechanicznego i dobór technologii produkcji, aby jego obsługa w późniejszym czasie odbywała się w miarę możliwości w równych i stałych odstępach czasu. Ponadto, poszczególne rodzaje resursów powinny spełniać warunki wielokrotności, urządzenia powinny posiadać konstrukcję modułową, umożliwiającą niezależną obsługę zespołów i podzespołów składowych. Zasadność stosowania obsług profilaktycznych urządzeń, których zakres i termin wykonania ustala się np. na podstawie diagnoz i prognozy ich stanu została opisana w [Kno2003]. Autor dokonuje analizy wprowadzenia dodatkowych obsług profilaktycznych, które mają za zadanie przywrócić urządzeniom mechanicznym pełną zdolność do wykonywania swych funkcji.



Rys. 1.18: Chwilowa i uśredniona intensywność użytkowania statku powietrznego: 1 – lot statku powietrznego, 2 – okres postoju.

Użytkownik statków powietrznych powinien dobrać intensywność użytkowania do wymagań oraz możliwości. W przypadku samolotów wojskowych myśliwskich, myśliwsko – bombowych o konstrukcji z lat 60. resurs do kasacji wynosił 2000 – 3000 godzin nalotu. Biorąc pod uwagę okres użytkowania wynoszący 20 – 25 lat wymuszało to na użytkowniku nalot na samolot maksymalnie 150 godzin rocznie. Część z samolotów w tym czasie nie wykonywała lotów. Znajdowała się ona w systemie obsługiwanym, wykonywane były obsługi planowane oraz nieplanowane, takie jak przeglądy, naprawy lub oczekiwanie na części zamienne. M.in. z tego powodu wymagana była duża flota statków powietrznych. Resurs współczesnych konstrukcji statków powietrznych wynosi około 10000 godzin do kasacji. Okres użytkowania wynosi 25-30 lat, co daje maksymalnie 300 godzin nalotu rocznie. Suma okresu eksploatacji stu nowoczesnych konstrukcyjnie samolotów odpowiada okresom eksploatacji 300 samolotów z lat 60. Ponadto nowszy konstrukcyjnie sprzęt wpływa nie tylko znacząco na zwiększenie zdolności obronnej państwa, ale również na poprawę bezpieczeństwa lotów. Natomiast w statkach powietrznych cywilnych nie występują tak znaczne przeciążenia jak w samolotach myśliwskich. Ich resurs bez remontu wynosi nawet 40000 godzin. Konstrukcja współczesnych silników umożliwia ich pracę przez ponad 25000 roboczogodzin.

Danilecki [Dan1995] wprowadza pojęcie podatności eksploatacyjnej, czyli zdolności do obsługi (użytkowalności), która jest pochodną procesu projektowania. Kształtuje się ją we wstępnej fazie projektowania i zależy od wielu czynników. Według [Bła2003] jest ona istotna dla personelu technicznego. Ma zasadniczy wpływ na przygotowanie statku powietrznego do lotu, decyduje również o czasie odtworzenia jego gotowości bojowej. Podatność eksploatacyjna samolotu jest zbiorem jego właściwości, określających jego przystosowanie do eksploatacji w konkretnych warunkach, które obejmują: podatność użytkową, obsługową, naprawczą i inne.

Im samolot jest lepiej przygotowany do eksploatacji, tym mniej czasu potrzeba na jego obsługiwanie. Dla porównania różnych statków powietrznych stosuje się wskaźniki i współczynniki zdolności obsługowej takie jak: współczynnik gotowości technicznej, pracochłonność obsługiwanego, nalot na jedno uszkodzenie, czas naprawy, czas odtworzenia gotowości, czas przezbierania i liczbę personelu załogi. Według [Bła2003] pracochłonność obsługiwanego, wyrażona liczbą roboczogodzin potrzebną do wykonania wszystkich obsług planowanych i nieplanowanych przypadającą na jedną godzinę lotu samolotu wynosi od 10 – 40 min. Im ta wartość jest mniejsza, tym więcej lotów można wykonać w planowanym czasie działań lotniczych. Pracochłonność przypadająca na godzinę lotu jest już obliczana w projekcie wstępnym (SP). Wartość ta jest następnie sprawdzana i korygowana w początkowym okresie eksploatacji. Określa się ją jako [Kam1997]:

$$K_t = K_{pl} + K_n, \quad (1.6)$$

gdzie: K_{pl} - pracochłonność obsługi planowego [rh/1godz lotu],
 K_n - pracochłonność obsługi nieplanowego (lokalizowanie i usuwanie niesprawności) [rh/1 godzinę lotu].

Pracochłonność obsługi nieplanowego oblicza się na podstawie znajomości niezawodności statku powietrznego, jako ilość godzin nalotu na jedną niesprawność. Według [Kam1997] średni czas naprawy oblicza się jako:

$$T_n = \frac{1}{n} \sum_{i=1}^n t_i, \quad (1.7)$$

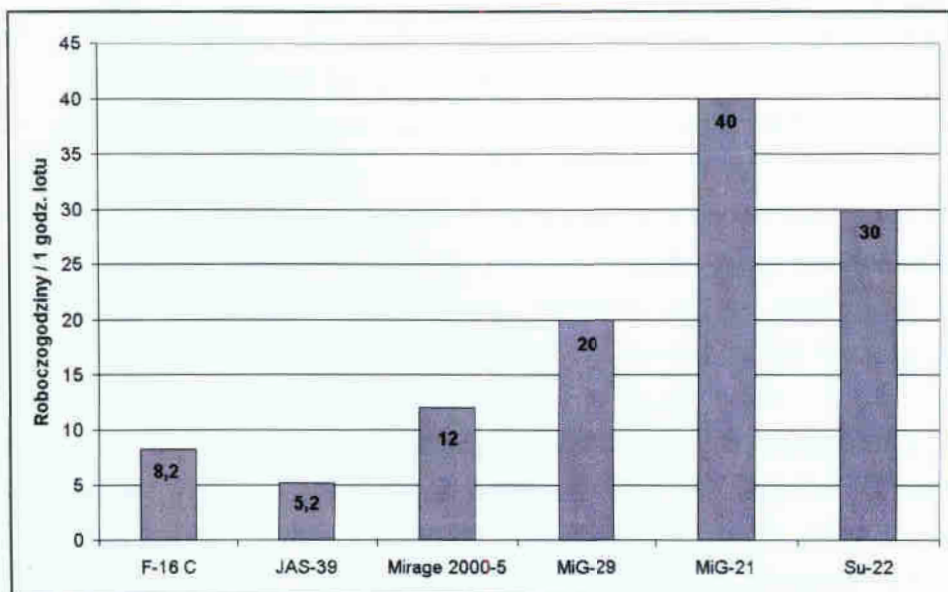
gdzie: $\sum_{i=1}^n t_i$ - czas usuwania uszkodzeń,
 n - liczba uszkodzeń.

Jednym z najważniejszych wskaźników jest liczba personelu inżyniersko – technicznego niezbędna do zapewnienia obsługi statku powietrznego. Dla starszych konstrukcyjnie typów statków powietrznych wynosi od kilkunastu osób do kilku specjalistów dla współczesnych samolotów. Wskaźniki podatności obsługowej dla współczesnych samolotów wojskowych zostały przedstawione w tabeli 1.2.

Tabela 1.2: Wskaźniki podatności obsługowej w lotnictwie wojskowym [Bła2003].

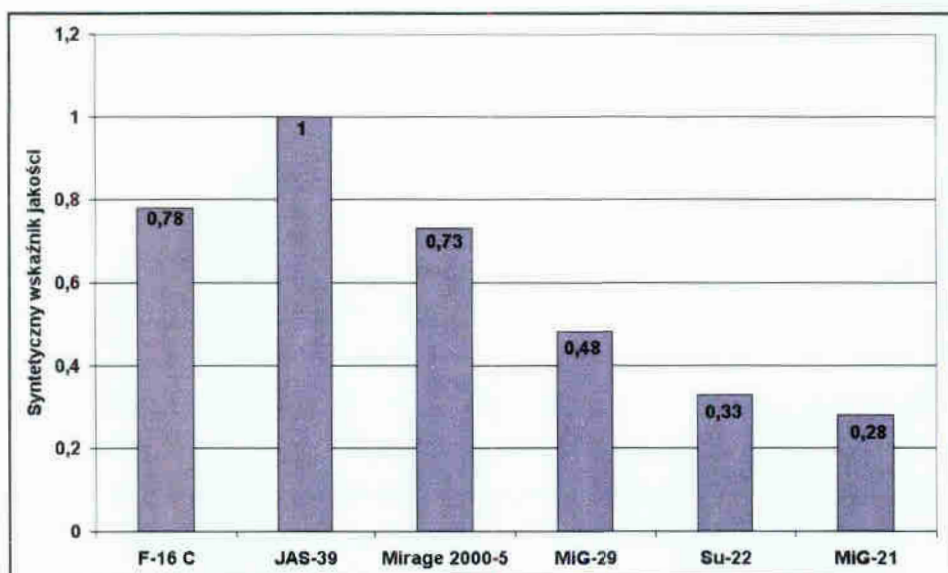
Typ samolotu	F-16C	JAS 39 Gripen	Mirage 2000-5	MiG-21	MiG-29	SU-22
Pracochłonność obsługi samolotu [rh/h _{lotu}]	8,2	5,2	12	40	20	30
Nalot na uszkodzenie [h _{lotu}]	2,8	7,5	1,3	4,5	7	8
Czas odtworzenia gotowości po locie [min]	15	10	15	40	20	40
Czas naprawy [min]	150	150	150	400	200	400
Liczba personelu obsługi	4	4	4	8	10	12

Na rysunku 1.19 przedstawiono wykres na którym pokazane są wartości pracochłonności obsługi statków powietrznych na jedną godzinę lotu. W przypadku konstrukcji z lat 60 – tych pracochłonność obsługi wynosi około 40 roboczogodzin (np. samolot MiG-21) zaś w przypadku samolotu JAS-39 Gripen - 5,2 roboczogodziny.



Rys. 1.19: Pracochłonność obsługi samolotów wojskowych na jedną godzinę lotu [Bła2003].

Na rysunku 1.20 zaprezentowany został ranking samolotów pod względem podatności obsługowej gdzie za 1 przyjęto własności eksploatacyjne samolotu JAS-39 Gripen. W tym przypadku również zauważalna jest różnica, jeśli chodzi o nowoczesność konstrukcji. Zdecydowanie od nowoczesnych samolotów bojowych do jakich należą JAS-39 Gripen oraz Mirage 2000-5 odbiegają statki powietrzne, które są na wyposażeniu polskiego lotnictwa, czyli MiG-21 oraz Su-22.



Rys. 1.20: Ranking samolotów wojskowych pod względem podatności obsługowej [Bła2003].

Celowe wydaje się wprowadzenie w eksploatacji urządzeń odpowiednio zorganizowanego procesu dozorująco-terapeutycznego, który składa się z podprocesów [Dąb2002]:

- a) dozoru – diagnozowania, którego celem jest śledzenie trajektorii stanów urządzenia (podrozdział 1.4);
- b) terapii – zapobiegania utracie stanu użyteczności urządzenia (poprzez regulację, wymianę).

W takim przypadku proces dozoru – terapeutyczny może być realizowany przez użytkownika urządzenia, bądź przez układ techniczny stanowiący uzupełnienie systemu antropotechnicznego człowiek – urządzenie. Pozwoli to na udzielenie odpowiedzi użytkownikowi w jakich warunkach należy przeprowadzać obsługę według „resursu”, a kiedy należy stosować obsługę według „stanu”.

Przedstawione powyższe dane wskazują jednoznacznie na konieczność stosowania nowoczesnych technologii i materiałów kompozytowych w lotnictwie. Pomimo, że koszt wytworzenia materiałów kompozytowych jest większy niż przy wykorzystaniu tradycyjnych materiałów jak np. duraluminium, należy rozważyć ich możliwość zastosowania w nowoczesnym sprzęcie. Szybko rosnące koszty eksploatacji starzejących się samolotów wymuszają ich wymianę w jak najkrótszym czasie. Według [Fli1999] nieopłacalna już nawet staje się modernizacja samolotów F-16, a od 2000 roku w Holandii rozpoczęto prace analityczne, zmierzające do odpowiedzi na pytanie o celowość eksploatacji po 2010 roku, zmodernizowanych F-16 w ramach programu MLU (Middle Life Update).

ROZDZIAŁ 2

NIEZAWODNOŚĆ W TECHNICIE LOTNICZEJ

2.1. Wprowadzenie w problematykę uszkodzeń statków powietrznych

Pomimo faktu, że współczesna technologia stosowana w wytwarzaniu umożliwia uzyskanie urządzeń mechanicznych, których prawdopodobieństwo sprawnego działania podczas eksploatacji jest stosunkowo duże – występują awarie. Dotyczą one również statków powietrznych, a w szczególności tych eksploatowanych przez wiele lat. W przypadku awarii statku powietrznego, jego zespoły lub instalacje przestają funkcjonować w sposób prawidłowy i stają się niezdolne do pracy. Utrata zdolności do realizacji funkcji przypisanej urządzeniu nazywana jest również uszkodzeniem [Cyu2000]. Po uszkodzeniu urządzenie może całkowicie stracić tę zdolność (uszkodzenie całkowite) lub tylko częściowo być wykorzystywane według przeznaczenia. Na przykład uszkodzenie busoli w statku powietrznym umożliwia pilotowi lot do lotniska według przyrządów zastępczych. US Air Force definiuje awarię jako utratę lub zniszczenie statku powietrznego. Według [Zag1997] zjawisko awarii może być różnie rozumiane, dlatego w niektórych źródłach używa się terminu stan awaryjny, który jest rozumiany jako każdy anormalny stan systemu antropotechnicznego zaistniały lub mogący zaistnieć w czasie jego eksploatacji.

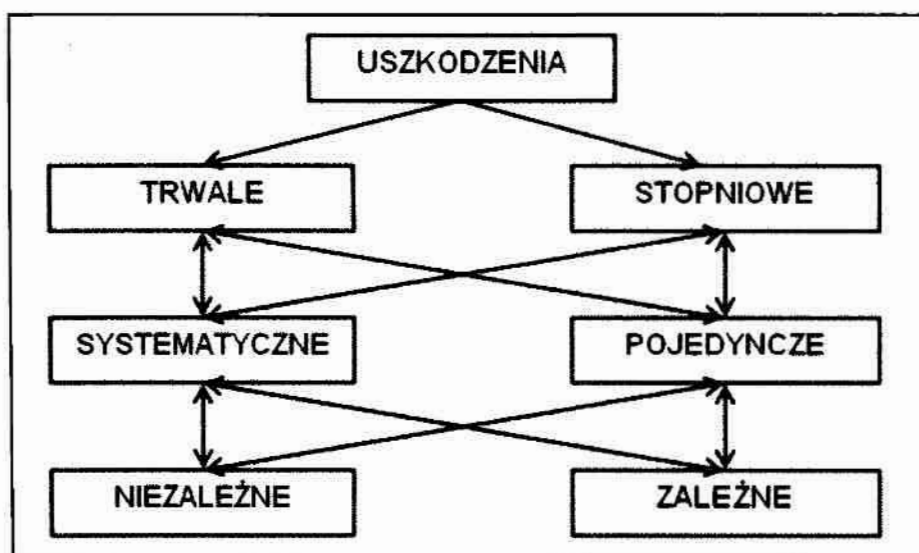
W przypadku statków powietrznych zaliczanych do urządzeń o wysokiej trwałości występują zazwyczaj uszkodzenia stopniowe, zdominowane przez zużywanie się elementów w procesie eksploatacji. Procesy zużywania są długotrwałe, statki poddawane są przeglądom (obsługom), podczas których dokonywana jest kontrola parametrów. Pomimo obsług i przeglądów zdarzają się stany awaryjne. Przykładem mogą być wypadki lotnicze, które wystąpiły na przestrzeni sześciu miesięcy, od października 1998 do marca 1999 [Fli1999]. US Air Force straciły sześć wielozadaniowych samolotów F-16. Przyczyną powyższych wypadków była niedostateczna wytrzymałość zmęczeniowa spawów dyszy i dopalacza. Pojawiające się niespodziewanie pęknięcia oraz szybka ich propagacja – szczególnie szybka podczas pracy w zakresie dopalania – były przyczyną odrywania się poszczególnych części dopalacza. Doprowadziło to do zderzenia samolotów z ziemią. Po tych zdarzeniach US AIR Force zawiesiło loty na samolotach F – 16 do czasu wyjaśnienia niesprawności. Podczas badań wykryto szereg pęknięć w obrębie spawów elementów dyszy i dopalacza. Ze względu na skalę zjawiska i powtarzalność niesprawności, świadczyło to o błędzie konstrukcyjnym. Powyższe zjawisko wystąpiło w silnikach F-100-220 i F-100-220E. Jedynym rozwiązaniem była wymiana kompletnych zespołów dopalacza i dyszy na zespoły stosowane w nowszych silnikach F-100-229,

których technologia produkcji nie przewidywała spawania. W związku z powtarzalnością uszkodzeń na kilku statkach powietrznych, należy je zakwalifikować do systematycznych. Jeśli uszkodzenia dyszy wystąpiłyby na jednym, dwóch statkach powietrznych F – 16, byłyby to uszkodzenia pojedyncze.

Zgodnie z charakterem występowania, uszkodzenia można podzielić na stopniowe i nagłe. Powyższy przykład wskazuje jednoznacznie na uszkodzenia nagłe, charakteryzujące się natychmiastową utratą zdolności do realizacji funkcji. Co więcej, wystąpieniu uszkodzenia nagłego nie towarzyszyło wcześniejsze pojawienie się symptomów zapowiadających to zdarzenie. Uszkodzenia nagłe są przyczyną większości katastrof lotniczych. Jedną z nich było uszkodzenie samolotu B – 747 w dniu 12 sierpnia 1985 r. W wyniku rozerwania się tylnej przegrody kabiny ciśnieniowej zginęło ponad 500 pasażerów i załoga [Lew2001]. Przyczyną było rozwinięcie się pęknięć zmęczeniowych, zainicjowanych w wyniku sposobu przeprowadzenia remontu tylnej części kadłuba po jej niewielkim uszkodzeniu eksploatacyjnym. Zastosowanie pojedynczego nitowania konstrukcji (zamiast podwójnego) doprowadziło do oderwania części ogonowej samolotu. Natomiast uszkodzenia stopniowe charakteryzują się stopniowym obniżaniem zdolności do realizacji funkcji przez urządzenie. Ich przyczyną są procesy zużywania i starzenia, inaczej mówiąc zmęczenie konstrukcji. Na jednym z wojskowych statków powietrznych podczas przeglądów okresowych po około 700 lotach, wykryto pęknięcia blach duralowych pokrycia kłap w rejonie wprowadzenia siły skupionej wciągника hydraulicznego. Kłapa zaskrzydłowa jest konstrukcją typu ulowego. Wprowadzenie siły skupionej bez pomocy żebra w płytę kłapy wywoływało znaczne spiętrzenie naprężeń i na skutek tego szybką inicjację wielu pęknięć zmęczeniowych. Rozwój pęknięć odbywał się równomiernie, ze stałą prędkością. Przeprowadzono badania doświadczalne, które wykazały, że kłapę zaskrzydłową, pomimo błędu konstrukcyjnego, można nadal eksploatować według zasady „bezpiecznego pęknięcia”. Na podstawie kryteriów aerodynamicznych wyznaczono maksymalną długość pęknięcia, jaką trzeba było przyjąć do okresowych badań nieniszczących. Zastosowanie odpowiedniego współczynnika bezpieczeństwa przez konstruktora i okresowe obsługi pozwoliły na uniknięcie katastrofy.

Według kryterium powiązania z pracą innych urządzeń, uszkodzenia można podzielić na niezależne i zależne. Uszkodzenia niezależne nie są związane z uszkodzeniami innych elementów. Uszkodzenia zależne mają wpływ na inne elementy. Na przykład, uszkodzeniu tarczy hamulcowej koła może towarzyszyć uszkodzenie osi koła. W tym przypadku uszkodzenie tarczy jest uszkodzeniem niezależnym, a uszkodzenie osi koła – zależnym.

Uszkodzenia urządzeń mogą być usuwalne lub takie, których nie można usunąć z przyczyn ekonomicznych, bądź technicznych. Elementy pomp paliwowych należą z reguły do nienaprawialnych, ze względów bezpieczeństwa. Nieopłacalne jest również remontowanie tarcz hamulcowych, żarówek, bezpieczników itp.



Rys. 2.1: Klasyfikacja uszkodzeń [Cyu2000].

Na prawidłowe funkcjonowanie urządzeń zasadniczy wpływ mają również kwalifikacje personelu eksploatującego i remontującego sprzęt. Poziom kwalifikacji, czyli przygotowanie do wykonywania określonego zawodu, osiągnięte doświadczenie, zdolność i chęć do pracy mogą mieć wpływ na stan techniczny urządzenia. W związku z tym, że praca operatora – pilota odbiega od optymalnych i wymaga dodatkowej energii, wiąże się to z zawsze ze wzrostem zmęczenia i zagrożeniem uszkodzenia statku powietrznego. Jak wykazały liczne obserwacje i badania, wypadki lub zakłócenia w pracy człowieka i urządzeń zdarzają się wówczas, gdy pod wpływem doraźnych przyczyn następuje załamanie się koordynacji motorycznej, psychicznej lub umysłowej istniejącej w normalnych warunkach pracy. Rozprężenie koordynacji wewnętrznej i załamanie się człowieka w systemie użytkowania powoduje nie tylko rozprężenie całego systemu, ale często zagraża zdrowiu i życiu ludzi i jest bezpośrednią przyczyną katastrof w lotnictwie. Przykładem może być katastrofa samolotu IŁ – 62M Kopernik, która nastąpiła w 1980 roku pod Warszawą. W wyniku rozkręcenia turbiny ponad wartość dopuszczalną prędkości obrotowej w wyniku pęknięcia wału, nastąpiło uszkodzenie trzech silników, rozerwanie jednej z tarcz turbiny i uszkodzenie popychaczy sterów wysokości i kierunku lotu. Pomimo wykonywanych planowych obsług międzyremontowych, popełnione zostały błędy technologiczne polegające na niezamierzonym wykonaniu karbu, w którym mogło się rozwijać pęknięcie zmęczeniowe. Ponadto, użyto materiału z zanieczyszczeniami wewnętrznymi.

Narastającą liczbą cykli pracy wału (zmiennych obciążeń) zarodkowanych w karbie mikropęknięcia rozwinęła się w pęknięcie zmęczeniowe, co doprowadziło do katastrofy. W katastrofie zginęło 87. pasażerów plus załoga. W wyniku podjętych badań wprowadzono nową technologię wytwarzania wałów silników odrzutowych.

W instrukcjach obsługi technicznych statków powietrznych zawarte są zalecenia, które bezwzględnie należy przestrzegać. M.in. we wszystkich przypadkach, po wymianie

pojedynczych agregatów lub kompletów aparatury, sprawdza się na statku powietrznym działanie całego układu, w skład którego wchodzi agregat lub cała aparatura. Nieprzestrzeganie powyższej zasady może doprowadzić do katastrofy. Przykładem może być odwrotne połączenie linek ze sterem podczas prac okresowych realizowanych w samolocie Jak-12. W czasie startu, pilot w celu podniesienia ogona statku powietrznego wychylił drążek od siebie. Przy odwrotnym podłączeniu ster wysokości wychylił się do góry, przez co wytworzona siła uniemożliwiła podniesienie tylnej części samolotu i start. W tej sytuacji samolot, po rozpędzeniu się do prędkości nieco większej od minimalnej, oderwał się od ziemi i przeszedł na wznoszenie. Pilot chcąc zmniejszyć kąt wznoszenia dalej wychylał drążek od siebie powodując tym dalsze wychylanie steru do góry, czyli dalsze pogłębianie wznoszenia. Po przekroczeniu krytycznego kąta natarcia, samolot „przepadł” zderzając się z ziemią. Oprócz personelu technicznego winę ponosi również pilot, ponieważ wiedząc o pracach remontowych w układzie sterowania samolotem, nie wykonał sprawdzenia poprawności działania sterów przed wykołowaniem.

W lotnictwie niedopuszczalne jest powierzanie rozpoczętej pracy przez jednego specjalistę innemu specjalście. W przypadkach szczególnych dopuszcza się możliwość wyznaczenia innego specjalisty, który obowiązany jest wykonać cały zakres obsługi od początku do końca, niezależnie od tego, w jakim stopniu zostały one wykonane przez poprzedniego specjalistę. Ponadto, każdorazowo przed rozpoczęciem i po zakończeniu pracy na sprzęcie lotniczym, osoby, którym zostały powierzone narzędzia mają obowiązek sprawdzić ich stan ilościowy. Niejednokrotnie zdarzało się, pozostawienie narzędzi w tunelu wlotowym silnika. Podczas uruchomienia następowało zassanie „ciała obcego” i uszkodzenie sprężarki.

W przypadku awarii statku powietrznego następuje wymiana uszkodzonego elementu. Najpierw musi być przeprowadzony demontaż w określonej kolejności. Problematykę związaną z demontażem, znalezienie optymalnej sekwencji demontażowej określono w pracy [Leb2002]. Umożliwia to zmniejszenie kosztów do minimum.

Z powyższych przykładów wynika stwierdzenie, że „od personelu obsługującego wymagane jest myślenie eksploatacyjne, wysokie poczucie odpowiedzialności za powierzony sprzęt lotniczy i rzetelność w spełnianiu swoich obowiązków na zajmowanym stanowisku służbowym. Długi czas pracy, wadliwe warunki pracy, przeżycia psychiczne, powinny być starannie eliminowane” [Lew2001].

2.2. Wskaźniki niezawodności w technice lotniczej

W celu oceny trwałości statku powietrznego można wykorzystać jeden ze wskaźników nazywany zasobem pracy lub trwałością urządzenia. Trwałość statku powietrznego jest jego zdolnością do zachowania określonych własności w granicach ich zmian, w określonych warunkach istnienia samolotu. Wymagania dotyczące trwałości powinny być określone precyzyjnie. Trafny dobór wskaźników w przypadku statku powietrznego jest istotny i może dotyczyć specyficznych wymagań stawianych eksploatowanemu sprzętowi.

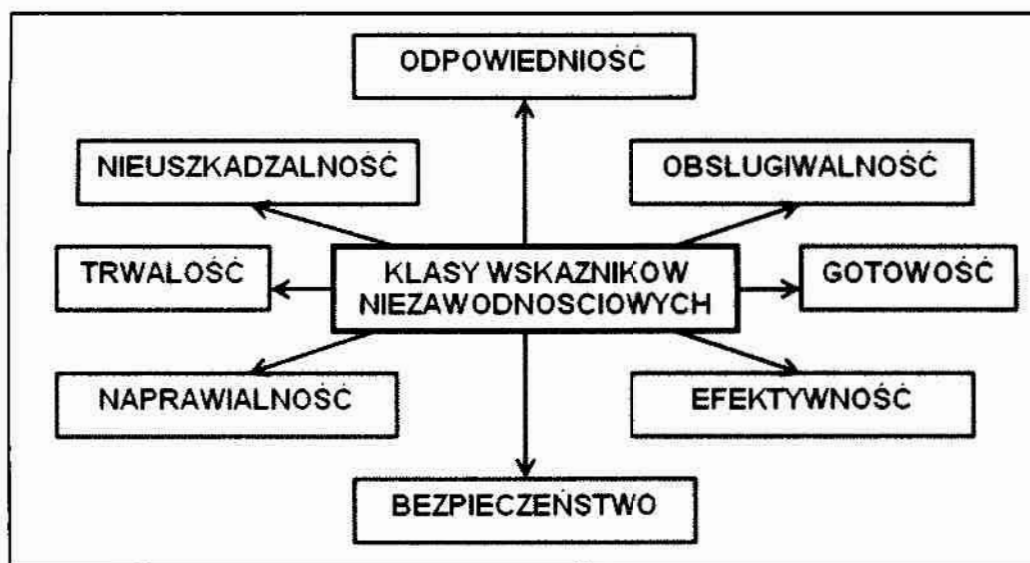
Ponadto świadczy o jakości wykonania samolotu. W przypadku statków powietrznych stawiane są następujące postulaty:

- a) bezawaryjnej pracy w okresie eksploatacji,
- b) występujące uszkodzenia w statkach powietrznych nie mogą powodować zagrożenia bezpieczeństwa ludzi, zniszczenia sprzętu, zanieczyszczenia środowiska,
- c) czas obsługi powinien być możliwie krótki, a czas eksploatacji pomiędzy obsługami możliwie najdłuższy (resurs międzyobsługowy).

Na rysunku 2.2 przedstawiono główne klasy wskaźników niezawodnościowych. Nieuszkodzalność jest mierzona prawdopodobieństwem $R(t)$ niewystąpienia uszkodzeń w procesie eksploatacji urządzenia, w określonym przedziale czasu i określonych warunkach eksploatacji. Funkcja $R(t)$ jest funkcją nierosnącą. Za miarę nieuszkodzalności przyjmuje się intensywność uszkodzeń λ [Słó1995]:

$$\lambda = \frac{q}{T_{1000}} \cdot 100\%, \quad (2.1)$$

gdzie: q – prawdopodobieństwo uszkodzeń urządzenia,
 T_{1000} – okres trwałości w czasie $T=1000$ godzin.



Rys. 2.2: Klasy wskaźników niezawodnościowych.

Na podstawie powyższego wskaźnika wyróżnia się 5 poziomów prawdopodobieństwa bezawaryjnej pracy urządzenia w czasie 1000 godzin:

- a) poziom O ($\lambda= 20\%$) – urządzenia, dla których niezawodność nie jest wymagana,
- b) poziom R ($\lambda= 1,5\%$) – urządzenia mało ważne,
- a) poziom S ($\lambda= 0,5\%$) – urządzenia mało ważne, dla których wymagana jest ocena niezawodności, w większości przypadków dla odbiorcy wojskowego,

- b) *poziom T* ($\lambda = 0.05\%$) – urządzenia ważne, dla których wymagana jest ocena niezawodności,
- c) *poziom U* ($\lambda = 0.005\%$) – urządzenia bardzo ważne, dla których wymagana jest ocena niezawodności (większość elementów wyposażenia statków powietrznych).

Inną miarą niezawodności jest funkcja wiodąca rozkładu prawdopodobieństwa czasu poprawnej pracy $\Lambda(t)$. Według [Lew1993/1] pomiędzy funkcjami $R(t)$, $\lambda(t)$ i $\Lambda(t)$ istnieje ścisły związek i do oceny nieuszkodzalności urządzenia wystarczy znać jedną z tych funkcji.

W przypadku statków powietrznych skutkiem uszkodzenia może być niewykonanie zadania, zagrożenie bezpieczeństwa lub niesprawne funkcjonowanie. Miara nieuszkodzalności w powyższym przypadku może być scharakteryzowana przez prawdopodobieństwo $R_z(t)$ niewystąpienia takich uszkodzeń urządzenia, których skutkiem jest niewykonanie zadania. Niewykonanie zadania może być mierzone za pomocą intensywności uszkodzeń $\lambda_z(t)$ oraz funkcji wiodącej rozkładu $\Lambda_z(t)$.

Statki powietrzne są eksploatowane do osiągnięcia stanu granicznego. Kres t_k życia urządzenia nadchodzi, gdy przestają być spełniane kryteria trwałości. Zbyt duże nakłady na eksploatację (przyczyny ekonomiczne) mogą również być przyczyną osiągnięcia wartości granicznej t_k . Warto nadmienić, że w przypadku urządzeń prostych np. żarówek, bezpieczników itp., kresem t_k jest chwila powstania pierwszego uszkodzenia.

Miarą trwałości statku powietrznego może być prawdopodobieństwo niewystąpienia stanu granicznego $R_g(t)$, intensywność występowania stanu granicznego $\lambda_g(t)$ oraz funkcja wiodąca rozkładu trwałości $\Lambda_g(t)$.

Miara bezpieczeństwa statku powietrznego określa prawdopodobieństwo $R_B(t)$ niewystąpienia w czasie realizacji uszkodzeń, których skutkiem byłoby zagrożenie bezpieczeństwa urządzeń zabudowanych na statku, osób go obsługujących. Zazwyczaj bezpieczeństwo określa się jako średni czas pracy urządzenia między uszkodzeniami, powodującymi zagrożenie bezpieczeństwa. Do wskaźników bezpieczeństwa zalicza się zawodność bezpieczeństwa $Q_B(t)$, intensywność uszkodzeń $\lambda_B(t)$ powodujących zawodność bezpieczeństwa, funkcja wiodąca rozkładu bezpieczeństwa $\Lambda_B(t)$, prawdopodobieństwo r_B niewystąpienia zawodności bezpieczeństwa pod warunkiem, że urządzenie jest uszkodzone.

Efektywność niezawodnościowa E statku powietrznego określa jego stopień przystosowania do realizacji oczekiwań użytkownika. Efektywność jest inaczej nazywana skutecznością. Odpowiedniością statku powietrznego jest jego własność opisującą jego przystosowanie do realizacji dowolnych zadań. Miarą jest prawdopodobieństwo D , że statek powietrzny jest odpowiedni do realizacji zadań. Obsługiwalność samolotu jest prawdopodobieństwem $F_\theta(t)$ terminowego wykonania obsługi. Do miar obsługiwalności należy intensywność obsługi $\lambda_\theta(t)$ oraz funkcja wiodąca rozkładu obsługi $\Lambda_\theta(t)$. Prawdopodobieństwo terminowego wykonania naprawy określa wskaźnik naprawialności

$F_n(t)$. Intensywność naprawy $\lambda_n(t)$ oraz funkcja wiodąca naprawy są miarami naprawialności.

Doboru powyższych wskaźników w zależności od eksploatowanego urządzenia dokonuje się na podstawie normy [Nor1977].

Opis wskaźników niezawodności w technice lotniczej można znaleźć m.in. w pracy profesora Danileckiego [Dan2001]. Jako najważniejsze z nich są wymieniane:

- wskaźnik niezawodności,
- **wskaźnik gotowości technicznej**,
- wskaźnik wykorzystania technicznego,
- prawdopodobieństwo poprawnej pracy,
- prawdopodobieństwo wystąpienia uszkodzenia,
- oczekiwany czas poprawnej pracy do uszkodzenia,
- oczekiwany czas pracy między uszkodzeniami,
- oczekiwany czas eksploatacji,
- oczekiwany czas naprawy,
- intensywność uszkodzeń.

Autor zauważa, że jednym z najczęściej stosowanych wskaźników jest wskaźnik gotowości technicznej statku powietrznego. *Definiowany jest on jako prawdopodobieństwo zdarzenia, że samolot będzie w stanie zdatności do lotu w dowolnej chwili czasu.* Oblicza się go jako:

$$\eta = \frac{MTBF}{MTBF + MTTR}, \quad (2.2)$$

gdzie: $MTBF$ - średni czas pracy bez uszkodzeń (Mean Time Between Failure),

$MTTR$ - średni czas naprawy (Mean Time To Repair).

Zakładając, że średni czas pracy bez uszkodzeń powinien wynosić 1000 godzin, a współczynnik gotowości określony jest jako 0,95, średni czas naprawy wynosi:

$$MTTR = \frac{MTBF - \eta \cdot MTBF}{\eta} = \frac{1000 - 0,95 \cdot 1000}{0,95} = 52,632 \text{ godz}$$

Dla wymaganego współczynnika gotowości technicznej η przyjmowane jest następujące kryterium:

$$\text{czas naprawy} \leq MTBF \times (1 - \eta)$$

W celu obliczenia współczynnika gotowości technicznej dla wybranych statków powietrznych przedstawionych w tabeli 1.2, przy założeniu, że bezpieczny okres użytkowania wynosi 1000h, a czas naprawy zgodnie z przedstawionymi wartościami w tabeli 1.2 można uzyskać następujące wartości wskaźnika gotowości technicznej według następującej zależności:

$$\eta(\text{dla samolotu } F - 16) = \frac{1000}{1000 + 2,5} = 0,99751,$$


$$\eta \text{ (dla samolotu MiG-21)} = \frac{1000}{1000 + 6,66} = 0,99338,$$

$$\eta \text{ (dla samolotu MiG-29 i SU-22)} = \frac{1000}{1000 + 3,33} = 0,99668.$$

Uzyskane wyniki wskazują jednoznacznie na to, że w przypadku statków powietrznych współczynnik gotowości technicznej osiąga wartości z przedziału (0,99; 1).

2.3. Stan techniczny statków powietrznych

Poprzez stan techniczny urządzenia należy rozumieć zbiór cech fizycznych urządzenia, mających wpływ na sposób realizowania funkcji celu (zadania), dla wypełnienia którego dane urządzenie zostało skonstruowane. W przypadku statku powietrznego jego stan techniczny zależy od właściwości jego zespołów w chwili początkowej $t=0$, czyli od początkowego stanu technicznego oraz od różnorodnych oddziaływań.



Rys. 2.3: Krzywa Lorenza przebiegu procesu zużycia np. w $[10^{-3} \text{ mm/h}]$; z – zużycie; z_g – zużycie graniczne; z_d – umowne zużycie przy docieraniu.

Podczas eksploatacji statków powietrznych, na skutek tarcia, erozji oraz korozji zachodzą w nich procesy zużyciowe i starzeniowe. Proces zużycia w funkcji czasu można opisać krzywą Lorenza przedstawioną na rys 2.3. Pierwszy etap określa zużycie elementów w okresie „docierania”. Drugi etap świadczy o normalnym przebiegu eksploatacji. W trzecim etapie następuje przyspieszone zużycie elementów.

Zużycie jest to proces, który powoduje zmniejszenie zasobu możliwości spełniania funkcji na skutek czynników oddziałujących na drodze fizycznej i/lub chemicznej. Jest on określany w drodze inspekcji i zależy z jednej strony od samego urządzenia, np. od wyboru materiału, ulepszenia cieplnego itp., a z drugiej strony od czynników zewnętrznych lub ograniczeń takich jak przebieg konserwacji, atmosfera sprzyjająca korozji, pył oraz od sposobu eksploatacji; od sposobu obciążenia (obciążenia gwałtowne, zmieniające się

nierównomiernie itp.). Do wielkości charakteryzujących proces zużywania zalicza się [Cyu2000]:

- a) zużycie – wartość określonego parametru urządzenia, np. w [10^{-3} mm/h],
- b) prędkość zużywania – zużycie elementu odniesione do czasu użytkowania w np. [10^{-3} mm/h],
- c) intensywność zużywania – zużycie elementu odniesienia do drogi tarcia w [mm/m].

Zmiana warunków eksploatacji powoduje wzrost lub zmniejszenie prędkości zużywania się elementów urządzenia. W przypadku statków powietrznych, przy występowaniu zmiennych warunków obciążenia i nierównomiernej jakości obsługi, proces zużycia w czasie normalnej eksploatacji traktowany jest jako losowy. W czasie sytuacji awaryjnej (np. zbyt duża temperatura w układzie wylotowym) gwałtownie wzrasta prędkość i wielkość zużycia elementów (np. zmniejsza się wytrzymałość łopatek turbiny przy długotrwałym oddziaływaniu wysokiej temperatury). Świadczy to o gwałtownym pogorszeniu jakości i niezawodności pracy turbiny.

Dla większości urządzeń, w których występuje tarcie ślizgowe wyróżnia się zazwyczaj trzy okresy przebiegu zużycia [Ty11998]:

- a) okres starzenia wstępnego,
- b) okres zużycia normalnego,
- c) okres zużycia przyspieszonego.

Okres starzenia wstępnego (docierania) występuje na początku współpracy elementów. Na przykład w początkowym okresie eksploatacji układu tarcza – klocek hamulcowy warstwy zewnętrzne są docierane, co wprowadza elementy w stan optymalny, charakteryzujący się zwiększoną odpornością na zużycie skojarzenia tych elementów. W tym okresie intensywność zużycia w największym stopniu zależy od czynników konstrukcyjnych i technologicznych. Okres starzenia wstępnego nierozzerwalnie jest związany ze znaczną intensywnością uszkodzeń spowodowanych ukrytymi wadami materiałowymi, błędami wytwarzania (montażu) oraz błędami w czasie przechowywania i transportu.


W okresie zużycia normalnego (ustalone warunki eksploatacji urządzenia) prędkość zużycia jego elementów można rozpatrywać jako ustaloną. Wtedy zasób pracy urządzenia określonego rodzaju określa się z zależności:

$$T = \frac{z_g - z_d}{u}, \quad (2.3)$$

gdzie:

$$u = \frac{z_2 - z_1}{t_2 - t_1} - \text{określa prędkość zużycia elementu}; \quad (2.4)$$

z_1, z_2 – wielkości zużycia elementu odpowiednio w czasie t_1 i t_2 .



Rys. 2.4: Określenie zasobu pracy urządzenia na podstawie pomiarów zużycia [Cyu2000].

Dla statków powietrznych można przyjąć, że $z_d=0$. Określenie prędkości zużycia urządzenia można przeprowadzić za pomocą zależności:


$$u = \frac{z}{t}, \quad (2.5)$$

gdzie: z – jest wielkością zużycia w czasie t .

Wówczas zasób pracy urządzenia przy ustalonych warunkach jego eksploatacji określony jest następująco:

$$T = \frac{z_g}{u}, \quad (2.6)$$

przy czym, w tym przypadku, prędkość zużywania się u jest prędkością graniczną: $u=u_g$.



Rys. 2.5: Funkcja zasobu zużycia [Paw1996].

Na rys. 2.5 przedstawiono wykres obrazujący przebieg zmian zasobu zużycia w czasie eksploatacji urządzenia. Przekroczenie granicy uszkodzeń jest równoznaczne z gwałtownym zmniejszeniem krzywej zasobu zużycia i należy spodziewać się awarii.

Zasób zużycia po naprawie może być większy niż dla nowego urządzenia na skutek modernizacji. W okresie zużycia przyspieszonego zostają przekroczone dopuszczalne luzy skojarzeń współpracujących elementów. Wskutek tego występują dodatkowe obciążenia dynamiczne wywołujące bardziej intensywne odkształcenia elementów, co w końcu może doprowadzić do awarii urządzenia. Na przykład tarcze hamulcowe na skutek przyspieszonego zużycia nie spełniają już swojej roli ponieważ następują nieodwracalne zmiany w jakości zastosowanego materiału.

Statki powietrzne, składające się z dużej liczby zespołów, z których każdy złożony jest również z pewnej liczby podzespołów, agregatów i elementów, w każdej chwili czasu t znajdują się w stanie $\xi(t)$. Stan techniczny samolotu jest opisany stanem zamontowanych na nim zespołów $\xi_1(t), \xi_2(t), \xi_3(t), \dots, \xi_m(t)$. Z kolei stan każdego zespołu opisany jest stanem podzespołów $\xi_{11}(t), \xi_{12}(t), \dots, \xi_{1n_1}(t), \xi_{21}(t), \xi_{22}(t), \dots, \xi_{2n_2}(t), \dots, \xi_{m1}(t), \xi_{m2}(t), \dots, \xi_{mn}(t)$. Na bezawaryjne funkcjonowanie statku powietrznego wywierają wpływ dwa rodzaje oddziaływań wymuszających:

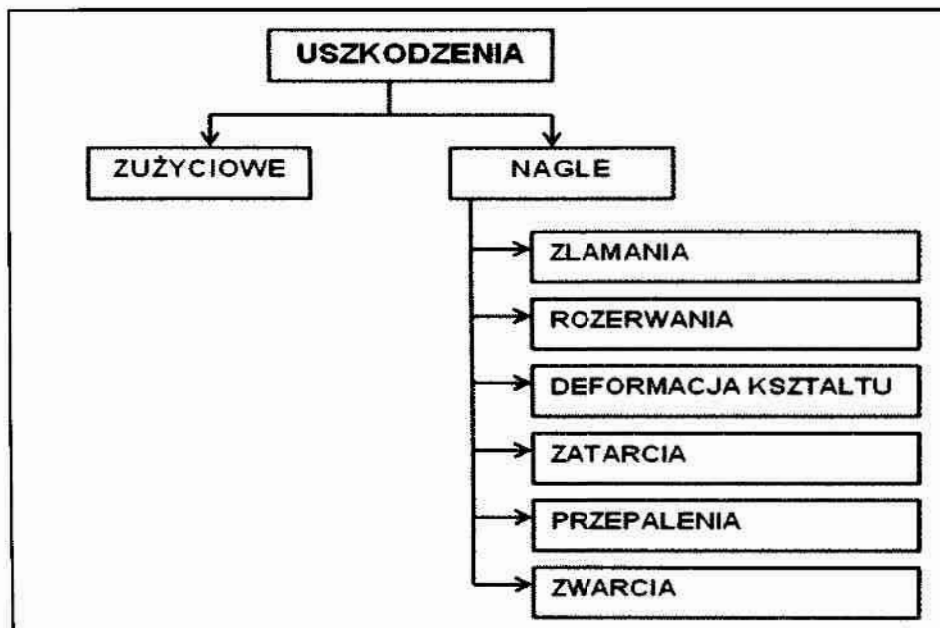
- a) oddziaływania destrukcyjne,
- b) oddziaływania odnawiające.

Oddziaływania destrukcyjne prowadzą do pogorszenia stanu technicznego statków powietrznych. Oddziaływania odnawiające prowadzą do utrzymywania lub odtwarzania stanu technicznego statków powietrznych. Są to m.in. obsługi zapobiegawcze i remontowe.

W przypadku elementów, w których występuje tarcie toczne (np. łożyska toczne) Tylicki [Tyl1998] wyróżnia dwa okresy zużycia:

- a) okres starzenia wstępnego,
- b) okres zużycia normalnego.

W okresie starzenia wstępnego zużycie współpracujących elementów jest niezauważalne, natomiast w drugim okresie zużycie jest nieznaczne. Wynika ono ze zgniotu warstwy wierzchniej. Jednak wraz z upływem czasu narastają zmiany zmęczeniowe spowodowane cyklicznym oddziaływaniem naprężeń w warstwach wierzchnich skojarzonych elementów tocznych, co prowadzi do ich przyspieszonego zużycia. Podobny przebieg zużycia można zaobserwować w przypadku urządzeń elektrycznych jak np. prądorozrusznik. Obok zużycia mechanicznego dodatkowo występuje erozja elektryczna, intensyfikująca ubytek masowy materiału zespołów (np. komutatora, szczotek, styków przekaźnika).



Rys. 2.6: Uszkodzenia w czasie eksploatacji statków powietrznych.

Występujące w czasie eksploatacji statków powietrznych uszkodzenia zespołów są związane ściśle z charakterem zmian wartości wymuszeń działających na statek powietrzny. W związku z tym, wyróżnia się uszkodzenia w postaci przedstawionej na rysunku 2.6.

Uszkodzenia zużyciowe są wynikiem nieodwracalnych zmian właściwości początkowych statku powietrznego, zachodzących podczas eksploatacji wskutek procesów starzenia i zużywania się. Występują one najczęściej w okresie zużycia normalnego, zależą od czynników eksploatacyjnych i prowadzą do czasowych lub stałych uszkodzeń zespołów powodując w konsekwencji niezdatność statków powietrznych do wykonywania zadań.

Uszkodzenia przypadkowe powstają w wyniku działania bodźców skokowych powodujących przekroczenie ustalonych wartości dopuszczalnych. Są związane z wadami konstrukcyjnymi i technologicznymi. Skutkiem tego może być utrata zdolności do pracy zespołu lub zespołów statku powietrznego. Uszkodzenia nagłe charakteryzują się skokową, niedopuszczalną zmianą wartości istotnych cech urządzeń, zespołów, elementów. Występują w trzech okresach eksploatacji statku powietrznego, a wywołane są działaniem wymuszeń o skokowej wartości widma. Na prawdopodobieństwo ich wystąpienia nie ma wpływu ani liczba godzin pracy, ani kalendarzowy okres eksploatacji urządzenia. Usunięcie uszkodzeń polega na regeneracji, bądź wymianie zespołów. Każde z powyższych uszkodzeń charakteryzuje się określonymi objawami. Utrata sztywności, bądź spistości elementu może świadczyć o jego złamaniu lub pęknięciu. Przerwa w pracy prądorozrusznika świadczy najczęściej o zwarceniu lub przerwie w instalacji elektrycznej urządzenia. Ubytki czynnika ciekłego takiego jak paliwo, olej są skutkiem nieszczelności.

Inną klasyfikację uszkodzeń można znaleźć w [Sło1996]. Uszkodzenia dzieli się na:

- a) uszkodzenia pierwotne,

b) uszkodzenia wtórne.

W przypadku uszkodzenia pierwotnego elementu, jest ono niezależne od miejsca w strukturze funkcjonalnej urządzenia i powstaje w wyniku procesu fizycznego występującego w danym urządzeniu. Uszkodzenia wtórne są skutkami uszkodzeń pierwotnych lub wynikają z wymogów procesu technologicznego.

Przyczyny powstawania uszkodzeń mogą być różnorodne. Uszkodzenia mogą występować na skutek błędów projektowania i konstrukcyjnych. W przypadku statków powietrznych założenia projektowe jak np. uwzględnienie zbyt „małych” wartości obciążeń ekstremalnych jest przyczyną mikropęknięć prowadzących do niesprawności zespołów. Wady materiałów zastosowanych w zespołach, błędy wykonania, brak tolerancji wymiarowej, gładkości powierzchni, niewłaściwa obróbka termiczna powoduje przejście w stan niesprawności. Do przyczyn eksploatacyjnych powstawania uszkodzeń zalicza się uszkodzenia powstałe w wyniku nieprzestrzegania obowiązujących zasad w eksploatacji lub na skutek oddziaływania czynników zewnętrznych nieprzewidzianych dla warunków użytkowania urządzeń. Długotrwałe wykonywanie lotu z przeciążeniem przekraczającymi dopuszczalne wartości, niewłaściwa kolejność czynności podczas obsługi mogą należeć do przyczyn eksploatacyjnych. Przykładem może być awaria samolotu SU-22UM3K opisana w [Lew2001]. Podczas startu jednego z samolotów (z załogą dwuosobową) na wysokości około 2-5 m odpadło prawe koło podwozia. Załoga samolotu wykonała lądowanie na wypuszczonej przedniej goleni podwozia, na części trawiastej lotniska, po wypracowaniu paliwa. Lądowanie odbyło się pomyślnie. Przyczyną był nieprawidłowy montaż prawego koła dokonany przez personel techniczny, polegający na dokręceniu nakrętki osi koła przy niezablokowanej podkładce zabezpieczającej. Starzeniowe przyczyny uszkodzeń są rezultatem nieodwracalnych zmian, prowadzących do pogorszenia wytrzymałości urządzeń.

Biorąc pod uwagę układ: „człowiek – statek powietrzny – otoczenie” każdy z tych elementów układu w czasie wykonywania zadania może znajdować się w jednym z charakterystycznych dla niego stanów sprawności technicznej. Pilot może znajdować się w jednym ze stanów zdatności do podejmowania poprawnych decyzji w trakcie lotu, otoczenie – w jednym ze stanów istotnych z punktu widzenia zachowania się samolotu lub pilota lub samolotu. Zmiana stanu rozpatrywanego podsystemu jest skutkiem zmian parametrów jego elementów wewnętrznych i ewentualnie zmian wywołanych oddziaływaniem współdziałających podsystemów. Czyli kombinacje stanów podsystemów określają stan systemu „statek powietrzny – pilot – otoczenie”. Wpływ parametrów elementów (podsystemów) systemu przedstawionego powyżej na prawdopodobieństwo wykonania zadania i zachowania zdatności elementów systemu do dalszej pracy w różnych fazach wykonywania zadania z wykorzystaniem sieci Petriego omówiono szczegółowo w pracy [Kap2000].

Podsumowując, przyczyny zawodności statków powietrznych mogą być:

- a) obiektywne, wywodzące się z natury rzeczy, niezależne od człowieka;

- b) zależne od człowieka jako podmiotu w procesach projektowania, wytwarzania i eksploatacji statków powietrznych.

Skutki zawodności statków powietrznych mogą być następujące:

- a) niemożność zrealizowania zadań,
- b) zagrożenie bezpieczeństwa ludzi i sprzętu,
- c) straty ekonomiczne, do których należą:
 - koszty utrzymania zdolności statków powietrznych,
 - straty przestojowe niesprawnego sprzętu,
 - rynkowe,
- d) deprecjacja wartości etycznych.

Przyczyny i skutki, jakie mogą wystąpić z zawodności obiektów technicznych opisano w [Cza2001]. Co więcej, w pracy wskazano drogę rozwiązywania przedstawionych powyżej problemów z wykorzystaniem elementów teorii niezawodności.

Uszkodzenia są uzależnione od rodzaju funkcji realizowanej przez urządzenie, od poziomu konstrukcji i jej unifikacji, od dokładności wykonania elementów, czynników eksploatacyjnych oraz rodzajów procesów zużycia. Użytkownika najbardziej interesują czynniki eksploatacyjne. Użytkownik może mieć wpływ na nie w okresie starzenia wstępnego, np. poprzez zastosowanie odpowiednich płynów eksploatacyjnych, w okresie zużycia normalnego np. postępując zgodnie z zasadami użytkowania i obsługi oraz w okresie zużycia przyspieszonego, poprzez zastosowanie odpowiedniej strategii obsługi, zmniejsza prawdopodobieństwo zużycia nagłego.

Podczas zużycia elementów zwiększają się luzy w parach kinematycznych, osłabiają się mocowania elementów i zmieniają się nastawy regulacyjne. Według [Tyl1998] następuje zmiana własności zespołów urządzeń, co powoduje zmianę procesów wyjściowych realizowanych przez pracujące zespoły urządzenia. Procesy wyjściowe opisuje się wielkościami mierzalnymi, mierzonymi bez demontażu urządzenia. Nazywane są one parametrami wyjściowymi, które świadczą o cechach ilościowych i jakościowych urządzenia. Na przykład w instalacji olejowej statku powietrznego będą to:

- a) cechy stanu: pęknięcia przewodów, zużycie uszczelek, zanieczyszczenia filtrów, opiłki metalu w oleju,
- b) parametry wyjściowe: poziom oleju, wydatek pomp, temperatura, ciśnienie, barwa i zanieczyszczenie oleju.

W przypadku podwozia statku powietrznego:

- a) cechy stanu: zużycia tarcz hamulcowych, łożysk koła, klocków hamulcowych lub opon,
- b) parametry wyjściowe: siła hamowania, skuteczność hamulców.

Na podstawie powyższych parametrów określa się cechy sygnału diagnostycznego, czyli parametry diagnostyczne, które zależą od stanu technicznego urządzenia. W celu wyznaczenia zbioru cech sygnałów diagnostycznego formułuje się następujące kryteria: jednoznaczność, dostateczna szerokość pola zmian, dostępność, które pozwalają uznać

parametry wyjściowe za parametry diagnostyczne. Należy wspomnieć w tym momencie o opracowaniu [Dan1995], w którym przedstawiono umotywowaną propozycję wykorzystania elementów mechaniki pękania do tworzenia nowych form systemu logistyki statków powietrznych.

2.4. Jakość w technice lotniczej


Współczesne lotnictwo wymusza stosowanie najnowszych technologii, co łączy się często z bardzo wysokimi nakładami finansowymi. Odpowiedni projekt, rozwiązania konstrukcyjne sprawiają, że efektem końcowym jest produkt wysokiej jakości, możliwe przy jak najmniejszych nakładach finansowych. Aby uzyskać jak najlepszą jakość, przy umiarkowanej cenie statku powietrznego musi być spełnione kilka kryteriów. Zamierzony efekt można uzyskać dzięki postępowi naukowo – technicznemu, zapewniającemu bardziej efektywne metody badawcze, oraz dzięki tańszym technologiom z wykorzystaniem komputerowych programów oraz programów symulacyjnych w badaniach). Ponadto zmniejszenie kosztów produkcji odgrywa znaczącą rolę w kształtowaniu ostatecznej ceny produktu. Ale to nie wszystko. Użytkownika interesują najbardziej koszty eksploatacji, które stanowią około 1/3 wszystkich kosztów. Żeby były najmniejsze, w statkach powietrznych niezbędne jest zastosowanie elementów wykonanych za pomocą najnowszej technologii.

Jakość eksploatacyjna statków powietrznych wyraża „*przydatność do spełniania zadań operacyjnych zdefiniowanych w wymaganiach taktyczno – technicznych*” [Lew2001]. Można rozpatrywać z punktu widzenia:

- a) kompleksowości cech,
- b) różnorodności cech,
- c) dynamiczności zmian w całym przedziale czasu eksploatacji statku powietrznego;
- d) zabezpieczenia utrzymania cech niezawodnościowych decydujących o bezpieczeństwie.

Wraz ze słabnącymi możliwościami operacyjnymi w stosunku do nowych konstrukcji, z upływem czasu, jakość eksploatacyjna ulega zmianie. Podczas obsługi okresowych podlega ona ocenie, co pozwala na podejmowanie właściwych decyzji o dalszej przydatności statków powietrznych do wykonywania zadań.

Aby uzyskać jak najlepszą jakość i niezawodność produktu, i związane z tym bezpieczeństwo personelu latającego, w technice lotniczej stosuje się systemy rezerwowe, nazywane nadmiarami. Rodzaje nadmiarów przedstawiono na rys. 2.7.



Rys. 2.7: Rodzaje nadmiarów w technice lotniczej.

Elementy systemów mogą uczestniczyć czynnie w realizacji zadań systemu lub być w rezerwie, przystępując do realizacji funkcji dopiero po uszkodzeniu się odpowiedniego elementu podstawowego. W takim systemie istnieje nadmiar strukturalny, świadczący o zastosowaniu elementów rezerwowych. Rezerwowaniu mogą podlegać nie tylko elementy systemu, lecz nawet cały system. Już w latach pięćdziesiątych ubiegłego wieku w konstrukcjach statków powietrznych stosowano systemy dublujące. Przykładem może być samolot MiG-21, który posiadał instalację zasadniczą powietrzną oraz instalację awaryjną, która służyła do wypuszczania podwozia, wychylania klap zaskrzydłowych podczas spadku ciśnienia w instalacji hydraulicznej. Według [Waż1990] wyróżnia się rezerwy:

- a) obciążeniowe (gorące) – własności niezawodnościowe elementu są jak w elemencie podstawowym,
- b) nieobciążeniowe (chłodne) – element z założenia jest absolutnie niezawodny,
- c) niedociążone (ciepłe) – element posiada zazwyczaj lepsze własności niezawodnościowe niż element znajdujący się w rezerwie obciążonej.

W niektórych przypadkach każdy z zamontowanych na samolocie podzespołów może realizować swoje funkcje. W przypadku uszkodzenia jednego z nich, drugi podzespół, częściowo lub całkowicie przejmuje funkcję podzespołu uszkodzonego. Powyższy fakt świadczy o związku funkcjonalnym pomiędzy podzespołami. W statkach powietrznych zastosowanie wysokościomierza barometrycznego pozwala pilotowi na określenie wysokości lotu. Zastosowanie radiowysokościomierza umożliwia określenie wysokości w ograniczonym zakresie. W przypadku awarii nadajnika ciśnienia powietrza pilot, wykorzystując radiowysokościomierz może wykonać przebijanie chmur w dół i określenie wysokości lotu, bez obawy zderzenia z powierzchnią ziemi. Ponadto zamontowanie w samolocie busoli magnetycznej oraz busoli żyroindukcyjnej świadczy o nadmiarze funkcjonalnym. W przypadku awarii zasilania pilot nie mógłby wykonać lotu bez widoczności ziemi z dokładnością umożliwiającą powrót do bazy. Natomiast

Wykorzystując wskazania busoli magnetycznej pilot może określić przybliżony kurs do punktu lądowania.

W statkach pasażerskich stosuje się zwykle dwa lub więcej silników. W sytuacjach awaryjnych istnieje możliwość wykonania lotu i lądowania w przypadku awarii jednego z nich. Świadczy to o nadmiarze parametrycznym. Nadmiar parametryczny odgrywa istotną rolę w systemach realizujących funkcje w zadanym przedziale czasu. Przykładem może być akumulator. Mimo, że napięcie akumulatora z uszkodzonymi ogniwami spełnia wymagania, akumulator powinien być naprawiony lub wymieniony. Naturalną miarą niezawodności statku powietrznego z nadmiarem parametrycznym jest efektywność. Uszkodzenie elementów powoduje pogorszenie parametru wyjściowego systemu, np. mocy silników lub napięcia źródeł energii elektrycznej, czyli efektów jego funkcjonowania.

Nadmiar informacyjny polega na zwielokrotnieniu określonej informacji. Ważne informacje są dublowane. Schowanie, bądź wypuszczenie podwozia statku powietrznego oprócz sygnalizacji świetlnej w kabinie, pilot określa na podstawie wskaźników mechanicznych, np. w samolocie TS-11 „Iskra”. Informacje o sytuacji nawigacyjnej, tzn. położeniu przestrzennym samolotu w powietrzu są podawane na wskaźnikach oraz są wyświetlane na wskaźniku HUD (Head Up Display). System z nadmiarem informacyjnym znajduje się w stanie zdatności, jeśli co najmniej jeden element systemu znajduje się w stanie zdatności. Warto zaznaczyć, że charakterystyczną cechą systemu z nadmiarem informacyjnym jest jego efektywność.

Nadmiar czasowy zespołów statku powietrznego jest określony jako czas, upływający od chwili powstania uszkodzenia w zespole samolotu do chwili niezawodności statku powietrznego. Jeśli zostanie uszkodzona instalacja olejowa silnika odrzutowego, czas, w jakim nastąpi zatarcie łożysk wału silnika określa nadmiar czasowy. W silnikach samolotowych spadek ciśnienia w instalacji olejowej jest sygnalizowany np. lampką braku ciśnienia oleju oraz manometrem ciśnienia – nadmiar informacyjny, co pozwala pilotowi na podjęcie określonych czynności.

Inne problemy dotyczące niezawodności w technice lotniczej zostały wyczerpująco przedstawione w [Dan1999].

2.5. Identyfikacja stanu technicznego statków powietrznych

W literaturze dotyczącej statków powietrznych, autorzy często przyjmują następujące założenia:

- a) stan techniczny samolotów określany jest za pomocą zbioru parametrów,
- b) zmiana stanu technicznego samolotów wyraża się poprzez losowe stopniowe zmiany wartości parametrów,
- c) zmiany wartości każdego z parametrów są niezależne, a zmiana wartości jednego z parametrów nie ma wpływu na zmianę wartości innego,

- d) eksploatacja statków powietrznych polega na utrzymywaniu ich w stanie zdadności i użyciu ich w miarę potrzeby,
- e) samoloty podlegają okresowej kontroli ich stanu technicznego, w wyniku której otrzymuje się informację o ich zachowaniu w funkcji czasu.

Specyfikacja eksploatacji statków powietrznych polega na tym, że magazynowane są one w stanie zdolnym do wykonywania zadań (w hangarach). Według [Tom2002] niezawodność i trwałość zespołów statków powietrznych odnosi się głównie do przechowywania – magazynowania samolotów. W wyniku procesów starzeniowych parametry opisujące stan techniczny ulegają zmianom i mogą mieć różny przebieg. Zmiany parametrów mogą polegać na:

- a) wzroście wartości parametrów w funkcji czasu przechowywania,
- b) obniżeniu wartości parametrów w funkcji czasu przechowywania,
- c) wahaniu wartości parametrów w funkcji czasu przechowywania.

Jeśli przyjmiemy, że liczba tych parametrów dla statku powietrznego wynosi N wtedy wektor stanu technicznego przyjmie postać $X=[x_1, x_2, \dots, x_n]$. Ponadto każdy z parametrów przyjmuje wartości z określonego przedziału, dla którego określony jest stan zdadności, jeżeli bieżące wartości parametrów są zawarte w przedziałach:

$$x_i \in [x_d^i, x_g^i] \quad (2.7)$$

gdzie: $i=1, 2, \dots, N$.

Jeśli wartości parametrów x znajdują się poza przedziałem (2.7) statek powietrzny uznaje się za niezdatny do lotu. Zależności niezbędne do wyznaczenia odchyłki od wartości nominalnej dla i -tego parametru przyjmują postać następującą:

$$\Delta y_i = \frac{x_p^i - x_n^i}{x_g^i - x_n^i}, \text{ gdy } x_p^i > x_n^i, \quad (2.8)$$

$$\Delta y_i = \frac{x_p^i - x_n^i}{x_d^i - x_n^i}, \text{ gdy } x_p^i < x_n^i,$$

gdzie: x_p^i - zmierzona wartość i -tego parametru;

x_n^i - nominalna wartość i -tego parametru;

x_g^i - górna granica przedziału dopuszczalnych wartości i -tego parametru;

x_d^i - dolna granica przedziału dopuszczalnych wartości i -tego parametru.

Powyższe zależności obowiązują dla całego zbioru parametrów. Rozpatruje się przypadki, gdy wartość bieżąca parametru może w czasie eksploatacji przyjmować losowo wartości dla i -tego parametru z przedziału określonego we wzorze (2.7), czyli może

przyjmować wartości większe i mniejsze od wartości nominalnej. Jedną z metod oceny efektywności eksploatacji przedstawiono w [Tom2002/2].

Każdy statek powietrzny po określonym czasie użytkowania traci pierwotne własności. Głównym celem użytkownika jest przywrócenie pierwotnego stanu i ponowne wprowadzenie go do eksploatacji. Aby osiągnąć ten cel należy przeprowadzić jego remont. Według [Kas1994] remonty (SP) wykonuje się w:

- a) zakładach produkcyjnych,
- b) przedsiębiorstwach eksploatujących sprzęt,

oraz dla wojskowych (SP) dodatkowo w:

- c) polowych warsztatach lotniczych,
- d) eskadrach technicznych jednostek,
- e) wojskowych zakładach lotniczych.

Rozróżnia się następujące rodzaje remontów:

- główne,
- średnie,
- bieżące,
- drobne.

Remonty główne są wykonywane w zakładach remontowych lub produkcyjnych w kraju i za granicą. Ich celem jest odtworzenie zdolności użytkowej (SP). Remonty średnie, bieżące i drobne są wykonywane w pododdziałach obsługowo-remontowych. Zadaniem remontów średnich jest usuwanie uszkodzeń instalacji pokładowych, agregatów i uszkodzeń konstrukcji płatowca. Celem remontów bieżących jest usuwanie mniej złożonych uszkodzeń, natomiast zadaniem remontów drobnych jest naprawa nieznacznych i drobnych uszkodzeń.

Podstawowym kryterium kwalifikowania uszkodzeń (SP) do poszczególnych rodzajów remontów jest pracochłonność trwania remontu. Czas pracochłonności pozwala na zakwalifikowanie określonej awarii do rodzaju remontu. Remont średni określa pracochłonność usuwania awarii od 1500 – 600 roboczogodzin (*rh*). Pracochłonność remontu bieżącego wynosi od 600*rh* do 200*rh*. Na remont drobny należy poświęcić > 200*rh*. Zgodnie z zarządzeniem Głównego Inżyniera Wojsk Lotniczych i Obrony Powietrznej, od 1993 roku obowiązują inne kryteria podziału remontów [God1998]:

- średni >870*rh*,
- bieżący >125*rh*,
- drobny >40*rh*.

Podczas obsług, kontroli i remontów statków powietrznych zbierane są informacje umożliwiające ocenę trwałości różnych instalacji statku powietrznego, w celu zachowania wymaganego poziomu niezawodności samolotu w procesie eksploatacji i przechowywania. Samoloty hangarowane, przygotowane do wykonania lotu powinny być niezawodne, gdyż mogą być użyte w każdej chwili po wykonaniu niezbędnych obsług przedstartowych.

Poziom niezawodności statków powietrznych określa niezawodność odniesiona do okresów między kontrolami.

2.6. Materiał statystyczny wykorzystany w badaniach

Statystykę awarii i niesprawności statków powietrznych w polskim lotnictwie można znaleźć m.in. w pracy [Zag1996], w której zaprezentowano prawdopodobieństwa wystąpienia stanów awaryjnych oraz możliwość ich zaistnienia w zależności od elementu konstrukcji wybranych typów statków powietrznych. Z uwagi na fakt, że podobne zestawienia danych można znaleźć w innych pracach, jak np. [Lew2001], analogiczną strukturę podziału zastosowano w niniejszej rozprawie.

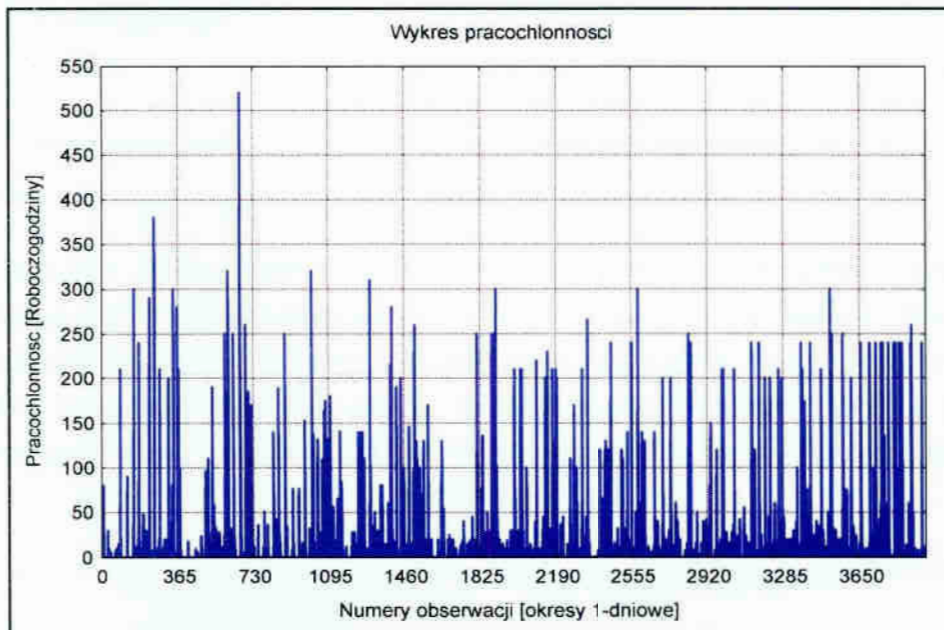
Badaniami objęto pracochłonność usuwania awarii wybranego typu statku powietrznego. Przetwarzane dane dotyczyły 36 sztuk samolotów eksploatowanych w jednym miejscu bazowania, w umownym okresie od listopada 1990 roku do stycznia 2001 roku. Badania dotyczą czasu poświęconego na naprawę statku powietrznego. Wyniki pracochłonności usuwania awarii przedstawiono w załączniku niniejszej pracy.

Ze względu na rodzaj awarii, które wystąpiły dokonano następującego podziału (SP) na podzespoły:

- a) płatowca, w którym wystąpiły awarie:
 - podwozia (kół, tarcz hamulcowych itp.),
 - układu sterowania (klap, lotek itp.),
 - instalacji hydraulicznych,
 - instalacji zasilania kabiny (SP),
 - instalacji pneumatycznej,
 - instalacji paliwowej,
 - instalacji tlenowej,
 - poszycia płatowca.
- b) silnika, w którym wystąpiły:
 - awarie instalacji paliwowej,
 - awarie instalacji tlenowej,
 - awarie tunelu wlotowego i sprężarki,
 - awarie komory spalania, turbiny i dopalacza,
 - awarie dyszy wylotowej,
 - awarie układu sterowania pracą silnika.
- c) urządzenia radio – elektroniczne:
 - awarie instalacji elektrycznej,
 - awarie urządzeń radiowych,
 - awarie stacji radiolokacyjnej,
 - awarie instalacji elektrycznej autopilota.
- d) urządzenia osprzętu:
 - awarie odbiornika ciśnień powietrznych,


- awarie autopilota,
- inne.

W okresie 10 – letniej eksploatacji wystąpiły 942 awarie o łącznej pracochłonności napraw 42320 roboczogodzin – *rh*. Analizę rozpoczęto od zgrupowania danych dotyczących pracochłonności. Maksymalna pracochłonność podczas remontu wynosiła 525*rh*, a minimalna 1*rh* dla okresów dziennych. Analizy szeregu czasowego rozpoczęto od wykonania graficznej ilustracji przebiegu szeregu. Na osi rzędnych zaznaczono okresy dzienne, podczas gdy na osi odciętych pracochłonność w *rh* usuwania awarii. Należy w tym miejscu zaznaczyć, że awarie dotyczyły wszystkich podzespołów statku powietrznego i zostały usunięte przez służbę techniczną w określonym przedziale czasu.




Rys. 2.7: Wykres zmiennej Pracochłonność.

W celu dokładnego przedstawienia pracochłonności napraw różnego rodzaju uszkodzeń, dokonano podziału statku powietrznego na podzespoły, zgodnie z charakterystyką zaprezentowaną na początku podrozdziału, a więc na: pracochłonność usuwania uszkodzeń płatowca, silnika, urządzeń radioelektronicznych (URE) oraz osprzętu. Uzyskane wyniki wraz z rodzajami awarii oraz pracochłonnością ich usuwania przedstawiono na rysunkach 2.8 – 2.17. Zestawienie rodzaju awarii, które wystąpiły w eksploatowanym sprzęcie, wraz z podziałem na podzespoły stanowi dorobek własny autora niniejszej pracy.



Rys. 2.8: Pracochłonność napraw podzespołów statków powietrznych.

Przy podziale statku powietrznego należy wyróżnić elementy uzbrojenia, jednak podczas badań statystycznych pominięto awarie dotyczące ww. elementów. Większa część pracochłonności usuwania awarii (około 53%) dotyczyła silnika i jego osprzętu, natomiast około 34% struktury płatowca statku powietrznego. Najmniej awarii, około 7% stwierdzono przy urządzeniach radiowo – elektronicznych i około 5% przy urządzeniach osprzętu.




Rys. 2.9: Podział pracochłonności napraw statków powietrznych ze względu na rodzaj obsług.

Niesprawności zostały wykryte podczas eksploatacji statków powietrznych, w czasie lotu, po wylądowaniu oraz podczas obsługi po 50,100,200h lotu. Wykres (rys 2.9) został sporządzony na podstawie zgromadzonych danych i przeprowadzonej analizie wykrycia awarii. W tym momencie, eksploatację samolotu celowo rozłożono na dwa elementy: lot i obsługi bezpośrednio z nim związane oraz obsługi okresowe. Ma to na celu uwypuklenie i zasygnalizowanie problemu związanego z awariami, dotyczącego czasu i miejsca określenia niesprawności.


Na usunięcie awarii po wykryciu uszkodzeń na statkach powietrznych poświęcono 13273rh (około 31%). Uszkodzenia wykrył personel latający i personel służby inżyniersko – lotniczej bezpośrednio w powietrzu i na ziemi. Świadczy to o konieczności ciągłej obserwacji, kontroli parametrów, nawet bez względu na to, czy statek jest bezpośrednio po wykonanym remoncie. Równie istotne okazują się obsługi po 200. godzinach lotu, których suma wynosi 13436rh, co stanowi 32% całej pracochłonności.

Na rys. 2.10 przedstawiono pracochłonność remontów poszczególnych instalacji płatowca. Całkowita pracochłonność wyniosła 14534rh. Pracochłonność usuwania niesprawności instalacji hydraulicznych, zasadniczej i wzmacniaczy stanowiły łącznie 5073rh, czyli 35% całkowitej pracochłonności. Związane to było z wyciekiem cieczy na połączeniach przewodów teflonowych hydraulicznych (uszkodzone uszczelki i przewody), awarią pomp hydraulicznych, zanieczyszczeniami cieczy hydraulicznej oraz krótkotrwałymi spadkami ciśnienia w instalacjach hydraulicznych. Według [Lew2003] niesprawności instalacji hydraulicznej zagrażają bezpośrednio bezpieczeństwu lotu. Na podstawie analizy awarii stwierdzono, że bardzo duży wkład do ogólnej liczby niesprawności wnoszą uszkodzenia wzmacniaczy hydraulicznych. Jest to związane z wymaganą bardzo dużą dokładnością pasowania ruchomych części, dużymi przeciążeniami (podczas lotu) oraz zanieczyszczeniami cieczy hydraulicznej. Analizę stanów awaryjnych oraz skutki uszkodzeń przedstawiono w pracy [Zbo2001]. Pracochłonność usuwania awarii instalacji paliwowej wynosiła 2173rh - (15%). Awarie, które wystąpiły, były spowodowane nieprawidłową sygnalizacją wypracowania paliwa oraz nieuszczelnnością zbiorników paliwowych. Usuwanie awarii pękniętych segmentów tarcz hamulcowych ceramicznych i bimetalicznych poprzez wymianę na nowe elementy oraz brak rozhamowania kół stanowiły 1082rh. Było to 7% całej pracochłonności usuwania awarii płatowca. Pomimo niewielkiej wartości pracochłonności 1082rh, wystąpiły 183 awarie kół w okresie 10 lat eksploatacji. Świadczy to o konieczności przeprowadzenia badań nad zastosowaniem bardziej wytrzymałych elementów tarcz. Pracochłonność napraw układu sterowania wynosząca 1036rh była związana z niewłaściwą regulacją lotek, zbyt dużym luzem kłap zaskrzydłowych oraz niwelacją układu sterowania sterem wysokości. Naprawa polegała głównie na regulacji luzów. Pracochłonność napraw i wymiany goleni podwozia wynosiła 1653rh - (17%), z czego niecałe 4% dotyczyła wymiany goleni (w związku z wypracowanym resursem kalendarzowym). Pracochłonność usuwania awarii instalacji pneumatycznych (zasadniczej

i awaryjnej) wynosiła 1419rh - (10%). W większości przypadków przyczyną niesprawności było uszkodzenie przewodów pneumatycznych oraz spadek ciśnienia w instalacjach. Awarie instalacji tlenowej oraz poszycia płatowca stanowiły niewielki odsetek niesprawności. W przypadku poszycia płatowca, przyczyną były uszkodzenia mechaniczne spowodowane zderzeniem podczas lotu z ptakami oraz niewłaściwa eksploatacją na ziemi. Awarie instalacji tlenowej polegały głównie na spadku ciśnienia w instalacji.




Rys. 2.10: Podział pracochłonności napraw płatowców ze względu na rodzaj awarii.



Rys. 2.11: Podział pracochłonności napraw płatowców ze względu na rodzaj obsługi.

Na rys. 2.11 przedstawiono pracochłonność remontów płatowca ze względu na rodzaj obsługi. Po wykryciu niesprawności podczas eksploatacji personel techniczny spędził 5066rh na usuwaniu awarii. Obsługi związane z wymianą goleni podwozia objęły 571rh. Stanowiło to wprawdzie niewielki odsetek - 4% wszystkich pracochłonności napraw płatowca, jednak nie sposób było pominąć tak istotny element, jak wymiana goleni. W przypadku płatowca istotne okazały się obsługi okresowe. Podczas obsług 50-godzinnych wykonano pracę 3425rh, przy 100-godzinnych awarie usuwano przez okres 2444rh, natomiast podczas obsług po 200 godzinach lotu czas naprawy łącznie wyniósł 5066rh.

Każdy silnik zabudowany na statku powietrznym składa się z wielu skomplikowanych zespołów, podzespołów o złożonych charakterystykach i instalacji umożliwiających jego normalną pracę. Na rys. 2.12 przedstawiono pracochłonność remontów poszczególnych instalacji silnika. Całkowita pracochłonność usuwania awarii silnika wyniosła 22442rh.




Rys. 2.12: Podział pracochłonności napraw silnika ze względu na rodzaj awarii.

Pracochłonność wymiany silników ze względu na wypracowany resurs wyniosła 7320rh. W niektórych przypadkach konieczny był demontaż uszkodzonej sprężarki przez zassanie ciała obcego np. ptaka – podczas lotu, drobnych kamieni z zanieczyszczonej drogi kołowania lub startowej, bądź przez zassanie narzędzia pozostawionego w tunelu wlotowym podczas prac okresowych. Wraz z wymianą ze względu na resurs pracochłonność wyniosła 9480rh. W związku z tym, że resurs, rozumiany jako czas pracy dokładnie ustalony przez producenta, nie może być przekroczony, w okresie 10 lat eksploatacji dokonano wymiany 31 silników. Ze względu na poprawną pracę silnika konieczna jest bezawaryjna praca instalacji paliwowej. Głównie awarie pomp paliwowych były przyczyną pracochłonności w ilości 2346rh. Zanieczyszczenia oleju służącego do smarowania i chłodzenia elementów pędni silnika poprzez opiłki metalu, oraz podcieki

spowodowane nieszczelnością wymusiły na personelu inżynieryjnym naprawy, które łączny czas wyniósł 442rh. Podczas regulacji agregatów silnika w celu uzyskania określonych parametrów pracy jak: temperatura gazów wylotowych, prędkość obrotowa pędni na poszczególnych zakresach pracy itp. łączna pracochłonność wynosiła 1450rh. Część problemów, z jakimi borykała się służba inżynieryjna dotyczyła dyszy wylotowej silnika. Element ten poddawany jest działaniu wysokiej temperatury oraz znacznym przeciążeniom. W tym przypadku pracochłonność wyniosła 3234rh. Natomiast w przypadku instalacji dopalacza, połączonej z dyszą i pracującą w podobnych warunkach cieplnych pracochłonność wyniosła 1939rh. Przyczyną były niewłaściwe parametry pracy. W niektórych przypadkach stwierdzono pęknięcia segmentów dyszy. W miejscu pęknięcia wywiercono otwory, co zapobiegło dalszemu rozprzestrzenianiu się pęknięć. Każda awaria silnika powinna być dokładnie przeanalizowana i powinny być wyciągnięte wnioski ze względu na wymagany wysoki poziom niezawodności.

Na rys. 2.13 przedstawiono pracochłonność remontów silnika ze względu na rodzaj obsługi.




Rys. 2.13: Podział pracochłonności napraw silników ze względu na rodzaj obsługi.

Czasookres 10% wszystkich obsługa był spowodowany wymianą silników po zassaniu ciała obcego i wyniósł 2160rh. W przypadku silników pracochłonność usuwania awarii, wynosząca 7098rh była skutkiem wykrycia niesprawności podczas obsługa po 50,100 i 200 godzinach lotu, natomiast po określeniu niesprawności podczas normalnej eksploatacji wykonano pracę w czasie 5864rh. Istotnym rodzajem obsługa było kontrolne wymontowanie silnika (KWS) na skutek konieczności sprawdzenia jego elementów. W okresie 10 lat wymontowano 12 silników w łącznym czasie 1462rh. W statkach

powietrznych nowszej generacji (jak np.: F-16 C,D; Mirage-2000-5 lub JAS-39 Gripen) wymiana silnika zajmuje tylko kilka godzin.


Na rys. 2.14 przedstawiono pracochłonność remontów URE ze względu na rodzaj awarii. Całkowita pracochłonność usuwania uszkodzeń wynosiła 2982rh. Nieprawidłowe działanie stacji radiolokacyjnej objawiające się brakiem znacznika celu na wskaźniku stacji, nieprawidłowym wypracowywaniem przez stację odległości do celu oraz przerwy w zasilaniu i chłodzeniu elementów stacji były przyczyną prac remontowych, których czasookres wyniósł 1826rh. Na skutek przepięć w instalacji elektrycznej statku powietrznego, bądź przepalenia bezpieczników wykonano prace o łącznym okresie czasu 74rh. Naprawa polegała na określeniu miejsca uszkodzenia, wymianie bezpiecznika, bądź przepalonego przewodu i przywróceniu samolotu do eksploatacji po sprawdzeniu działania. Brak łączności radiowej był przyczyną prac remontowych w czasie 246rh. Natomiast nieprawidłowe działanie instalacji elektrycznej autopilota objawiające się samoczynnym obrotem statku powietrznego wokół osi podłużnej, było przyczyną braku utrzymywania zadanych kątów pochylenia i przechylenia w określonym zakresie. Z tego powodu czasookres prac naprawczych wyniósł 836rh i obejmował 28,04% całkowitej pracochłonności napraw URE. Przypadki awarii instalacji elektrycznej autopilota powinny być wnikliwie analizowane, ponieważ w lotach w chmurach w nocy, przy przechwytywaniu celów powietrznych samoczynny obrót statku powietrznego może być przyczyną błędnych złudzeń i doprowadzić do utraty orientacji przestrzennej, co niejednokrotnie powodowało katastrofy.



Rys. 2.14: Podział pracochłonności napraw URE ze względu na rodzaj awarii.


Na rys. 2.15 przedstawiono pracochłonność remontów URE ze względu na rodzaj obsługi. Pracochłonność 45,57% wszystkich niesprawności URE była skutkiem ich

wykrycia podczas eksploatacji statku powietrznego. Podczas obsługi po 50 godzinach lotu wykryto i usunięto awarie w czasie 874rh, co stanowiło 29,31% całkowitej pracochłonności URE. Przy obsługach po 100 godzinach lotu wykonano prace remontowe w czasie 457rh, natomiast w przypadku obsług po 200 godzinach nalogu łączny czas naprawy wyniósł 292rh.



Rys. 2.15: Podział pracochłonności napraw URE ze względu na rodzaj obsługi.


Na rys. 2.16 przedstawiono pracochłonność remontów osprzętu ze względu na rodzaj awarii. Czasochłonność wszystkich napraw wyniosła 2362rh. Podobnie jak w przypadku URE większość czasu, czyli 58,43% spędzono przy naprawach części osprzętowej autopilota.



Rys. 2.16: Podział pracochłonności napraw osprzętu ze względu na rodzaj awarii.

W wyniku awarii odbiorników ciśnien powietrza wykonano naprawy w czasie 758rh, natomiast w wyniku przeskalowywania przyrządów z powodu ich nieprawidłowych wskazań wykonano prace naprawcze o łącznym czasie 126rh.

Na rys. 2.17 przedstawiono pracochłonność remontów osprzętu ze względu na rodzaj obsługi. Pracochłonność wykrytych awarii podczas eksploatacji wyniosła 980rh. Również w tym przypadku istotne okazały się obsługi okresowe, podczas których łączna pracochłonność usuwania niesprawności wynosiła 1382rh.



Rys. 2.17: Podział pracochłonności napraw osprzętu ze względu na rodzaj obsługi.

Należy podkreślić, że w przedstawionym powyżej materiale statystycznym nie podano czasochłonności normalnych obsług po 50, 100 i 200 godzinach lotu, bez wystąpienia awarii. Powyższe obsługi były wykonywane zgodnie z przyjętym planem i resursem. Były to setki czynności, w których sprawdzano poziom oleju oraz ciśnienia w instalacjach zgodnie z książkami obsług. Podczas wykonywania napraw występuje zapotrzebowanie na specjalistów od płatowca, silnika, URE lub osprzętu. Wiąże się to m.in. z planowaniem urlopów, dlatego też celowe wydaje się określenie pracochłonności w następnym roku. Można to wykonać różnymi metodami prognozowania. Wybór metody prognozowania jest uzależniony od:

- długości szeregu (od ilości zgromadzonych danych),
- występowania składników cyklicznych,
- wielkości wariancji składnika losowego w porównaniu z innymi rodzajami zmienności szeregu,
- „gładkości” szeregu,
- horyzontu prognozy.

Jeden z algorytmów wyboru modelu i metod prognozowania w zależności od szeregu został przedstawiony w [Lew2003]. Do prognozowania niezawodności eksploatacyjnej autor szczególnie poleca metodę wyrównywania wykładniczego.

Zaprezentowane powyżej dane można scharakteryzować przy pomocy statystyk opisowych przedstawionych w tabeli 2.1. Kolorem niebieskim zaznaczono zmienną dotyczącą wszystkich awarii statków powietrznych, natomiast kolor czerwony charakteryzuje zmienną dotyczącą napraw płatowca. Wyróżnione zmienne zostaną wykorzystane do predykcji ze względu na największą częstotliwość występowania awarii.

Tabela 2.1: Statystyki opisowe przedstawionych zmiennych.

Zmienna	Liczba przypadków	Średnia arytmetyczna	Mediana	Suma	Min	Max
Pracochłonność	122	346,89	337,50	42320	0	1072
Płatowiec		114,45	120,00	13963	0	211
Silnik		106,25	122,00	12962	0	284
Osprzęt		19,36	17,50	2362	0	64
URE		24,44	16,00	2982	0	92
Wymiana silnika		29	326,90	240,00	9480	0
Wymiana goleni	8	71,38	63,50	571	63	127

Zmienna	Wariancja	Odch. Std	Współcz. zmienn.	Skośność	Kurtoza
Pracochłonność	56217,74	237,10	68,35%	0,68852	0,22716
Płatowiec	3259,04	57,09	49,88%	-0,22966	-0,77517
Silnik	6687,06	81,77	76,96%	-0,01354	-1,26391
Osprzęt	392,20	19,80	102,27%	0,61392	-0,85259
URE	615,16	24,80	101,47%	0,93689	-0,26557

Wymiana silnika	20465,02	143,06	43,76%	1,25752	0,87789
Wymiana goleni	505,41	22,48	31,49%	2,82569	7,98836

Przedstawione w tabeli 2.1 wartości zostały obliczone w następujący sposób:

- a) **średnia arytmetyczna** obliczona według wzoru:

$$\bar{x} = \frac{1}{n} \sum_{j=1}^n x_j, \quad (2.9)$$

- b) **mediana** zdefiniowana została jako wartość, która dzieli rozkład wszystkich wartości na dwie połowy, to znaczy, że 50% wszystkich wartości leży poniżej mediany i 50% wartości powyżej mediany, oblicza się ją ze wzoru:

$$M_x = \frac{x_{(n+1)}}{2}, \quad (2.10)$$

- c) **wariancja** jest obliczona jako suma kwadratów odchyłeń (od średniej) podzielona przez $n-1$:

$$\hat{S}_x^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2, \quad (2.11)$$

- d) **odchylenie standardowe** dla rozkładu normalnego oblicza się jako pierwiastek kwadratowy z sumy kwadratów odchyłeń (od średniej) podzielonej przez $n-1$:

$$\hat{S}_x = \sqrt{\frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2}, \quad (2.12)$$

- e) **skośność** jest miarą asymetrii rozkładu, jeśli wartość ta byłaby równa 0 to rozkład wtedy byłby symetryczny:

$$\hat{A}_x = \frac{n \sum_{j=1}^n (x_j - \bar{x})^3}{(n-1)(n-2)\hat{S}_x^3}, \quad (2.13)$$

- f) **kurtoza** jest miarą wysmukłości rozkładu. Jeśli rozkład jest zbliżony do rozkładu normalnego wówczas kurtoza jest równa zero, oblicza się ją ze wzoru:

$$\hat{C}_x = \frac{n(n+1)\sum_{j=1}^n (x_j - \bar{x})^4 - 3\left[\sum_{j=1}^n (x_j - \bar{x})^2\right]^2 (n-1)}{(n-1)(n-2)(n-3)\hat{S}_x^4}, \quad (2.14)$$

g) **współczynnik zmienności** został obliczony ze wzoru:

$$\hat{V}_x = 100 \left(\frac{\hat{S}_x}{\bar{x}} \right), \quad (2.15)$$

Pomimo dosyć dużych wartości współczynnika zmienności dla zmiennej dotyczącej napraw wszystkich podzespołów (SP) oraz płatowców przeprowadzone zostanie prognozowanie.

ROZDZIAŁ 3

METODY STATYSTYCZNE W PROGNOZOWANIU PRACOCHŁONNOŚCI NAPRAW

3.1. Wstęp

Na wstępie, należy wyjaśnić znaczenie słowa „prognozowanie”. Według [Dit2000/1] przez prognozowanie rozumie się „racjonalne, naukowe przewidywanie przyszłych zdarzeń”. Przewidywanie racjonalne oznacza, że proces wnioskowania przebiega od sformułowania przesłanek prognostycznych do budowy prognozy, a przewidywanie naukowe – że korzysta się przy tym z dorobku nauki, tj. teorii i narzędzi badawczych. Wynik tego procesu nazywa się prognozą. Według [Cie2001] przez prognozę należy rozumieć sąd o następujących właściwościach:

- a) sformułowany z wykorzystaniem dorobku nauki,
- b) odnoszący się do określonej przyszłości,
- c) weryfikowalny empirycznie,
- d) niepewny, ale akceptowany.

W technice lotniczej każda prognoza odnosi się do obiektu lub systemu, którym może być: statek powietrzny, przedsiębiorstwo, człowiek, kraj itp. W obiektach zachodzą zjawiska: gospodarcze, fizyczne, psychiczne, chemiczne, biologiczne i inne, które można opisać za pomocą zmiennych. Wyróżnia się zmienne ilościowe, czyli wielkości, oraz zmienne jakościowe. Przykładową prognozą zmiennej ilościowej może być stwierdzenie: „wymiana tarcz hamulcowych w roku 2005 nastąpi w 20 eksploatowanych statkach powietrznych”. W przypadku zmiennej jakościowej: „częstotliwość awarii statków powietrznych w 2006 roku będzie na poziomie ‘średnim’.

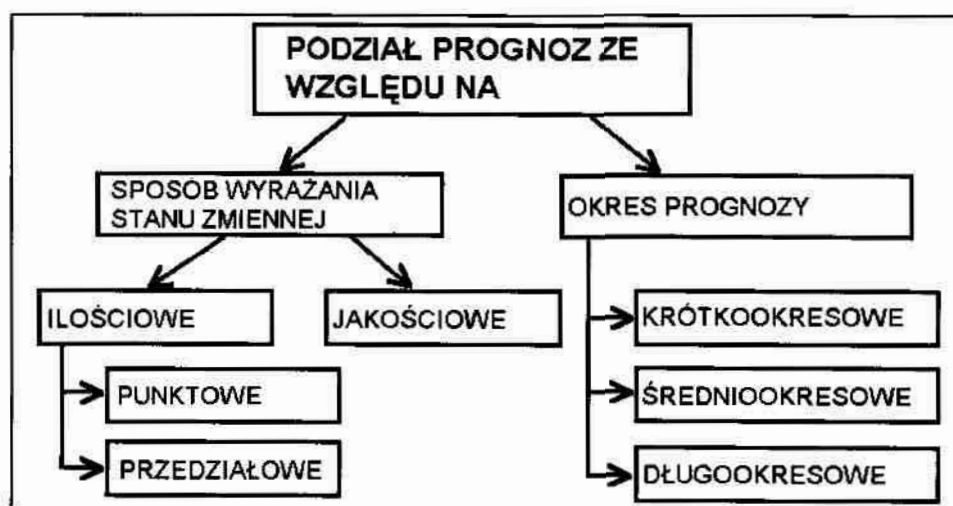
Zjawiska opisywane za pomocą jednej zmiennej nazywane są prostymi. Do nich należy pracochłonność napraw statków powietrznych, ponieważ do jej opisu wystarczy użyć danych dotyczących wielkości napraw (np. w roboczogodzinach/tydzień, miesiąc, rok). Do opisu zjawisk złożonych należy użyć więcej niż jedną zmienną (np. ilość pilotów/statek powietrzny, wyposażenie w uzbrojenie, paliwo, płyny eksploatacyjne itp.). W pierwszym przypadku prognoza określa stan jednej zmiennej, natomiast w drugim stan wielu zmiennych.

Empiryczna weryfikacyjność prognozy oznacza, iż samo sformułowanie prognozy jest precyzyjne (np. nie jest to stwierdzenie, że „pracochłonność napraw układu sterowania statkiem powietrzny się zwiększy”) i że jest określony *explicite* czas, w którym prognoza ma być sprawdzona.

Z powyższych rozważań wynika klasyfikacja prognoz, którą przedstawiono na rys. 3.1.

Prognozy dzieli się ze względu na sposób wyrażania stanu zmiennej, tj. określania zdarzenia prognozowanego oraz ze względu na przebieg zmian prognozowanej zmiennej prognozy. Prognozę nazywa się ilościową, gdy stan zmiennej wyrażony jest liczbą. Wyróżnia się następujące prognozy ilościowe:

- a) punktowe, podające, że zmienna przyjmie określoną wartość;
- b) przedziałowe, gdy podaje się przedział liczbowy, który obejmie przyszłą wartość zmiennej.



Rys. 3.1: Podział prognoz.

Jeżeli prognozowanym zdarzeniem jest stan zmiennej jakościowej lub słownie opisana sytuacja, taką prognozę określa się jako jakościową. Oto przykład: „w marcu 2004 roku pracochłonność napraw silników wzrośnie”. Metody jakościowe nazywane są inaczej metodami heurystycznymi, niematematycznymi, bądź subiektywnymi [Wel1998].

W prognozowanym zjawisku mogą zachodzić zmiany ilościowe i jakościowe. Zmiany ilościowe polegają na zmianie wartości zmiennej prognozowanej, zgodnie z dotychczas zaobserwowanymi prawidłowościami, np. z trendem, a zmiany jakościowe – na zmianie dotychczasowych prawidłowości, np. trendu czy czynników oddziałujących na zmienną prognozowaną. W zależności od tego, które z tych zmian (ilościowe czy jakościowe) zachodzą w prognozowanym zjawisku, prognozy dzieli się na krótko-, średnio- i długookresowe [Dit2000/1].

Za prognozę krótkookresową uważa się prognozę budowaną na taki przedział czasu, w którym zachodzą tylko zmiany ilościowe. Konstrukcja prognozy, oparta wówczas zwykle na inercji zjawiska, polega na ekstrapolacji dotychczasowego trendu lub zaobserwowanych związków. Dla przedsiębiorstw prognoza krótkookresowa odnosi się zwykle do najbliższych 2 – 3 miesięcy, natomiast dla kraju – do 1 roku. Według [Cie2001] o charakterze prognozy decyduje wielkość obiektu oraz istota zachodzących w nim zjawisk. W przypadku dużego obiektu jako całości, nawet w stosunkowo długim przedziale czasu prognozy mogą mieć charakter prognoz krótkookresowych.

Prognoza średniookresowa dotyczy takiego przedziału czasu, w którym oczekuje się, że w prognozowanym zjawisku wystąpią zarówno zmiany ilościowe i niewielkie zmiany jakościowe. W przypadku przedsiębiorstwa średniookresowy horyzont prognozy wynosi od 3 miesięcy do 2 lat.

Prognoza długookresowa jest konstruowana na taki okres czasu, podczas którego występują zmiany zarówno ilościowe, jak i jakościowe. W przypadku prognoz długookresowych okres prognozy wynosi od 2 do 10 lat dla przedsiębiorstwa. Podane wyżej okresy mogą mieć różne wartości w niektórych dziedzinach. W meteorologii krótkookresowe prognozy wynoszą do 24 godzin, średniookresowe do kilku dni, natomiast długookresowe do miesiąca. Wszystko jest uzależnione od konkretnego przypadku.

Wśród innych popularnych kryteriów klasyfikacyjnych prognoz wyróżnia się między innymi kryteria:

- a) funkcji spełnianej przez prognozę: prognozy strategiczne i operacyjne;
- b) celu prognozy: prognozy normatywne, ostrzegawcze oraz prognozy badawcze;
- c) stopnia szczegółowości: prognozy ogólne i szczegółowe;
- d) zasięgu: prognozy mikroekonomiczne i makroekonomiczne;
- e) wpływu decydenta na prognozowaną zmienną: prognozy zmiennych sterowanych i niesterowalnych;
- f) dostępności danych dotyczących zmiennych objaśniających: prognozy *ex post* i *ex ante*, w pierwszym przypadku wartości zmiennych objaśniających są znane, natomiast w drugim nie są znane.

Użytkownika zwykle interesuje faktyczny stan techniczny urządzenia. Aby to określić, należy przeprowadzić prognozowanie. Można tego jednak dokonać tylko dla takich elementów lub podzespołów, które mają określony, regularny charakter zmian parametrów. Przy rozwiązywaniu tego typu problemów niezbędne jest rozpatrzenie trzech zagadnień:

- a) określenie parametru lub cechy prognozującej,
- a) wybór aparatury kontrolnej,
- b) opracowanie metody prognozowania:
 - statystycznej,
 - porównawczej.

Metoda statystyczna polega na określeniu średniego czasu niezawodnej pracy elementów i obliczeniu czasu ich wymiany. Metodę tą stosuje się jedynie przy absolutnej powtarzalności wykonania, jakości użytych materiałów konstrukcyjnych i ich obróbki, warunków montażu i bardzo zbliżonych warunków eksploatacji. W takim wypadku czas wymiany elementów określa się według wzoru:

$$T_w = T_0 - k\sigma - \Delta t_0, \quad (3.1)$$

- gdzie: T_0 - średni czas niezawodnej pracy elementu;
 k - wskaźnik ufności; przy normalnym prawie rozkładu T_0 przyjmuje się, z dostateczną dla praktyki dokładnością, że $k = 2$;
 σ - średnie odchylenie standardowe T_0 ;
 Δt_0 - czas pracy elementu między kolejnymi obsługami okresowymi.

W celu zapobieżenia uszkodzeniom urządzenia należy bezwzględnie wymienić jego zawodne elementy podczas obsługi okresowej. Dlatego we wzorze na T odejmuje się Δt od granicznej wartości czasu niezawodnej pracy. Powyższą metodę można stosować tylko do urządzeń eksploatowanych według rezerwu.

W metodzie porównawczej wykorzystuje się analizę zmian charakterystyk niezawodności lub parametrów pracy. Analiza charakterystyk niezawodności $\lambda(t)$, celowa jest do prognozowania np. niezawodnej pracy poszczególnych elementów zespołu napędowego. W tej metodzie rozróżnia się dwa przypadki:

- znana jest zmiana intensywności uszkodzeń prognozowanych elementów w zależności od różnych czynników, np. nalotu,
- nie jest znana zmiana intensywności uszkodzeń.

W pierwszym przypadku prognozowanie sprowadza się do okresowego sprawdzania zgodności rzeczywistej wartości λ ze znaną z poprzednich badań wartością. Polega to na ciągłym nadzorowaniu rzeczywistych zmian λ w porównaniu ze znanymi wartościami z uprzednich badań eksploatacyjnych. W takim przypadku prognozuje się niezawodną pracę dla krótkich okresów eksploatacji. Długość okresu zależy od charakteru zmiany krzywej $\lambda(t)$ oraz od warunków pracy elementu. Np. jeżeli w chwili czasu t $\lambda = const$ oraz $\frac{d\lambda}{dt} = 0$, to można się spodziewać, że w krótkim czasie użytkowania $t_1 \dots t_2$ nie nastąpi zmiana wartości λ . Natomiast jeśli w czasie $t_3 \dots t_4$ wystąpiła zmiana krzywej $\lambda(t)$, to prognozowanie niezawodnej pracy w przedziałach $t_4 \dots t_5$ i $t_5 \dots t_6$ według $\frac{d\lambda}{dt}$ jest utrudnione. Znajomość rzeczywistych charakterystyk $\lambda(t)$ elementów jest korzystna, ponieważ można eksploatować elementy do początku okresu starzenia, co zwiększa niezawodność całego układu i pozwala na efektywne wykorzystanie elementów. Wadą tej metody jest brak możliwości przeniesienia wyników statystycznych analizowanego zbioru na poszczególne elementy (SP). Ponadto wyniki prognozowania są bardziej wiarygodne dla dużej liczby badanych elementów i nadają się głównie do określenia liczby części zamiennych [Kam1997].

Gdy nie jest znana zmiana intensywności uszkodzeń należy dokonywać okresowej kontroli zmian prognozującego parametru, biorąc pod uwagę dwie możliwości:

- zmiana wartości parametru jest znana (np. badania eksperymentalne),
- zmiana jest nieznaną.

W pierwszym przypadku okresowe sprawdzanie wartości parametru odbywa się po czasie t_1, t_2, \dots, t_g . Po upływie czasu t_g element musi być wymieniony lub naprawiony. W drugim przypadku stosuje się metodę ekstrapolacji, podobnie jak przy analizowaniu $\lambda(t)$.

Przy prognozowaniu uszkodzeń należy uwzględnić obciążenia jakim był, jest i będzie poddawany zespół. Przykładowo w USA, w celu dokładniejszego określenia obciążeń zmęczeniowych, którym poddawane są np. poszczególne podzespoły silników, wprowadzono umowne cykle obciążeń np. termicznych:

$$TAC = n_A + \frac{n_B}{4} + \frac{n_C}{40}, \quad (3.2)$$

gdzie: n_A - liczba zmian zakresów pracy od uruchomienia do „militarnego”;

n_B - liczba zmian zakresów pracy od minimalnego do „militarnego”;

n_C - liczba zmian zakresów pracy od przelotowego do „militarnego”.

Z przeprowadzonych badań samolotu F-16 z silnikiem F-100 firmy Pratt & Whitney, obciążenia na jedną godzinę lotu wynoszą 2...2,5 cykła [TAC].

3.2. Wybór metody prognozowania

W literaturze problemu można znaleźć różne metody prognozowania. W praktyce do prognozowania używa się zazwyczaj kilku metod, a następnie dokonuje się porównania wyników bądź uśrednia się prognozy uzyskane za pomocą dwóch lub więcej metod prognozowania. Głównym celem jest zmniejszenie błędu prognozy. Stąd też, bardzo ważny jest wybór odpowiedniej metody do rozwiązania określonego zadania prognostycznego. Użytkownikowi zależy na zastosowaniu jak najprostszej metody i jednoczesnym uzyskaniu wyników obarczonych najmniejszym błędem. Według [Dit2000] przy wyborze metod prognozowania spośród różnych ich własności należy zwrócić uwagę na: horyzont budowanych za ich pomocą prognoz, liczbę okresów, do których odnoszą się budowane prognozy, koszty zastosowania metod, dokładność uzyskiwanych prognoz oraz prostotę i łatwość ich stosowania. Wymaga to od prognosty nie tylko wiedzy o właściwościach metod, lecz również bardzo dobrego rozeznania sytuacji prognostycznej. Podstawą wyboru metody według [Cie2001] są przesłanki prognostyczne, obejmujące hipotezy o dotychczasowym oraz przyszłym mechanizmie rozwojowym zjawiska, dostępne dane prognostyczne oraz właściwości metod prognozowania. Przyjęcie przez prognostę postawy pasywnej zakłada wykorzystanie w procesie budowy prognozy inercji zjawiska jako nieuniknionego, pojedynczego następstwa przeszłości. W takim przypadku zadaniem prognosty jest konstrukcja prognozy przez ekstrapolację dotychczas zaobserwowanych prawidłowości w przyszłość. Przyjęcie postawy aktywnej charakteryzuje się uznaniem przyszłości za stosunkowo niezależną od przeszłości oraz przyjęcie założenia, że zaobserwowane prawidłowości mogą, lecz nie muszą się zmienić w przyszłości.

Jedną z najczęściej stosowanych klasyfikacji metod prognozowania jest podział na metody ilościowe i jakościowe. Pierwsze z nich są oparte na modelu prognostycznym,

zbudowanym na podstawie danych dotyczących kształtowania się wartości zmiennej prognozowanej i zmiennych objaśniających w przeszłości. Metody jakościowe oparte są na sądach pojedynczych ekspertów lub grup ekspertów. W takim przypadku modele prognostyczne używane przez ekspertów nie są modelami formalnymi tylko myślowymi.

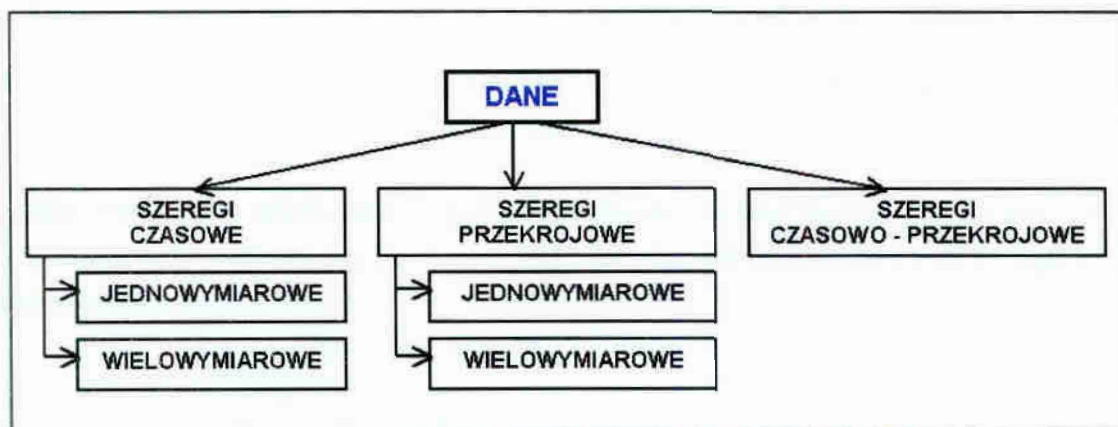
Do metod ilościowych zalicza się:

- a) modele szeregów czasowych,
- b) modele analogowe,
- c) modele zmiennych wiodących,
- d) modele analizy kohortowej.

W takim przypadku w metodach jakościowych wyróżnia się:

- a) opinie kierownictwa,
- b) opinie ekspertów.

Dane wykorzystywane do konstrukcji prognoz występują zazwyczaj w postaci szeregów przedstawionych na rys.3.2.



Rys. 3.2: Podział szeregów danych.

Dane występujące w postaci jednowymiarowego szeregu czasowego są ciągiem zaobserwowanych stanów zmiennej Y i są uporządkowane według wartości zmiennej czasowej t , ($t = 1, \dots, n$). W tym przypadku szereg czasowy jest zapisywany jako wektor $(1 \times n)$:

$$Y = [y_1, y_2, \dots, y_n], \tag{3.3}$$

gdzie: Y_t – jest stanem zmiennej Y w momencie lub okresie t ,
 n – liczba obserwacji (długość szeregu czasowego) zmiennej Y .

Gdy budowana prognoza jest prognoza wektorową i dotyczy wielu zmiennych Y_1, Y_2, \dots, Y_G opisujących urządzenie, dane służące do jej konstrukcji mają postać szeregu wielowymiarowego, który jest macierzą $(G \times n)$:

$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \\ \dots & \dots & \dots & \dots \\ y_{G1} & y_{G2} & \dots & y_{Gn} \end{bmatrix}, \quad (3.4)$$

gdzie: y_{gt} – jest to stan g – tej zmiennej w okresie t ; ($g = 1, 2, \dots, G$; $t = 1, 2, \dots, n$),
 G – liczba budowanych prognoz (liczba zmiennych opisujących urządzenie).

Przykładem dwuwymiarowego szeregu czasowego jest macierz utworzona przez dwa szeregi czasowe zmiennych Y_1 i Y_2 , opisujących badany obiekt. Zmienna Y_1 może być „Pracochłonnością (wyrażoną w roboczogodzinach) usuwania awarii”, natomiast zmienna Y_2 jest „liczbą pracowników uczestniczących przy usuwaniu awarii”. Uzyskany szereg dwuwymiarowy jest macierzą ($2 \times n$):

$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \end{bmatrix},$$

gdzie: y_{1t} – pracochłonność w okresie czasu t ($g=1, \dots, G$; $t=1, \dots, n$),
 y_{2t} – ilość pracowników w okresie t ($g=1, \dots, G$; $t=1, \dots, n$).

Jednowymiarowy szereg przekrojowy jest ciągiem zaobserwowanych stanów zmiennej Y , z których każdy odnosi się do tego samego okresu lub momentu t i do k -tego obiektu przestrzennego:

$$Y = [y_1, y_2, \dots, y_K], \quad (3.5)$$

gdzie: y_k - jest to stan zmiennej Y w obiekcie k – tym ($k = 1, 2, \dots, K$) w momencie lub okresie t .

Szeregi przekrojowe zmiennych Y_1, \dots, Y_G rozpatrywane w jednym okresie lub momencie t tworzą wielowymiarowy szereg przekrojowy, który może być wyrażony wzorem:

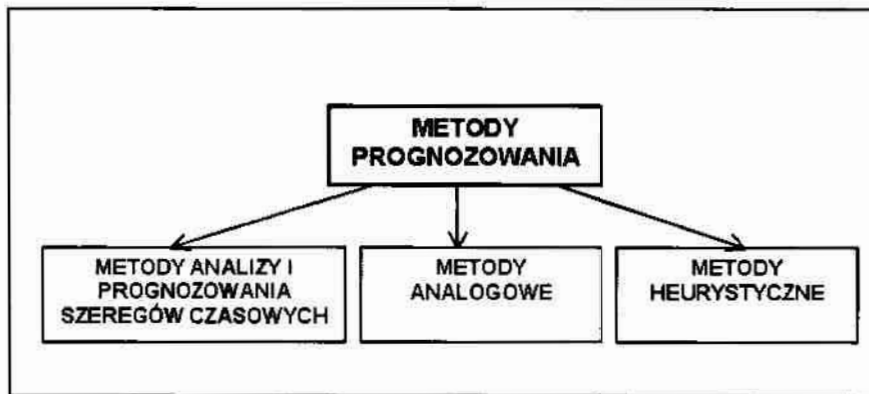
$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1K} \\ y_{21} & y_{22} & \dots & y_{2K} \\ \dots & \dots & \dots & \dots \\ y_{G1} & y_{G2} & \dots & y_{GK} \end{bmatrix}, \quad (3.6)$$

gdzie: y_{gt} – jest to stan g – tej zmiennej w k – tym obiekcie w okresie t ,
($g = 1, 2, \dots, G$; $t = 1, 2, \dots, K$).

Szereg przekrojowo – czasowy tworzą szeregi czasowe G zmiennych opisujących K obiektów. Szereg przekrojowo – czasowy jest macierzą blokową, a każdy blok zawiera wielowymiarowy szereg czasowy, charakteryzujący k – ty obiekt:

$$Y = \begin{bmatrix} Y^1 \\ Y^2 \\ \dots \\ Y^K \end{bmatrix}, \quad (3.7)$$

gdzie: Y^k - jest macierzą typu (3.3), a ($k = 1, 2, \dots, K$).



Rys. 3.3: Podstawowe grupy metod prognozowania.

Na rys. 3.3 przedstawiono podstawowe grupy metod prognozowania, wydzielone ze względu na rodzaj wykorzystywanych danych i sposób ich przetworzenia.

Do metod analizy i prognozowania szeregów czasowych zalicza się:

- a) metody średniej ruchomej;
- b) metody wygładzania wykładniczego;
- c) analityczne i adaptacyjne modele tendencji rozwojowej;
- d) modele składowej periodycznej;
- e) modele autoregresyjne;
- f) łańcuchy Markowa.

Metody analizy i prognozowania szeregów czasowych są stosowane zazwyczaj do sporządzania prognoz krótkookresowych. Prognoza korzysta w diagnozowaniu przeszłości zjawiska z danych o dotychczasowym kształtowaniu się zmiennej prognozowanej. Dane są przedstawione w postaci szeregu czasowego, który może być jedno- lub wielowymiarowy. Na podstawie ukrytych prawidłowości w szeregu czasowym otrzymuje się prognozę. Charakterystyczne dla tego rodzaju metod jest założenie, że na zmienną prognozowaną będą oddziaływać w ten sam sposób jak dotychczas, te same co dotąd czynniki [Cie2001].

Metody analogowe są stosowane w przypadku prognoz średnio- i długookresowych. Są stosowane do prognozowania określonej zmiennej w przypadku posiadania przez prognozę danych o zmiennych podobnych, które nie są powiązane ze zmienną prognozowaną. Przykładem zmiennych może być taka sama liczba statków powietrznych w różnych przedsiębiorstwach transportowych, lub różna np. liczba statków powietrznych w przedsiębiorstwie i liczba silników lotniczych. Przyszłe wartości zmiennych podobnych

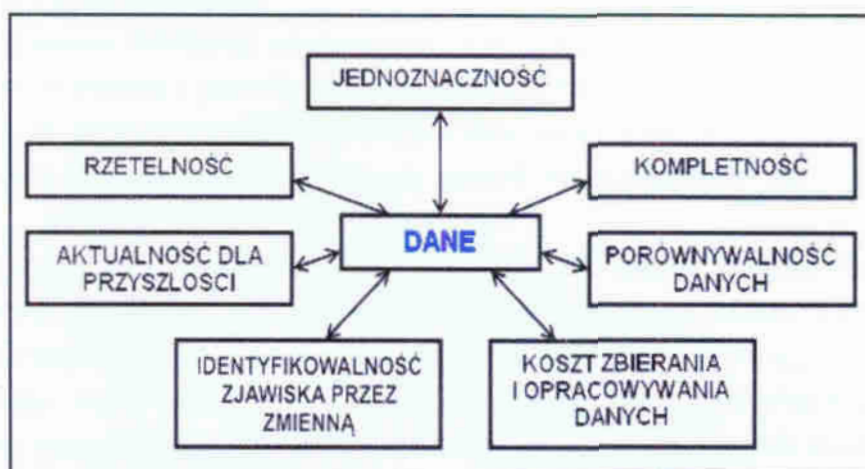
wykorzystuje się do obliczenia prognoz zmiennej badanej. Istotą metod analogowych jest określenie wspólnych dróg rozwojowych różnych zmiennych.

Metody heurystyczne są zazwyczaj stosowane w przypadku odkryć naukowych, technologii itp. Prognozy są uzyskiwane poprzez wykorzystanie wiedzy ludzkiej. Są one oparte na intuicji i doświadczeniu ekspertów w określonych dziedzinach nauki. Na podstawie własnego doświadczenia eksperci są w stanie określić kierunki przyszłych zmian ilościowych i jakościowych w prognozowanym zjawisku. Do metod heurystycznych zalicza się:

- a) burzę mózgów;
- b) metodę wpływów krzyżowych;
- c) metodę delficką.

Jest rzeczą oczywistą, że w każdej z powyższych metod decydującą rolę odgrywa ekspert, gdyż to on w głównej mierze decyduje o wyborze metody. Wybór metody prognozowania zależy również m.in. od rodzaju zgromadzonych danych. Według [Cie2001] w procesie prognozowania wykorzystuje się dane o urządzeniu, dla którego sporządza się prognozę oraz o urządzeniach – obiektach stanowiących jego otoczenie. Pierwsze z nich nazywane są danymi wewnętrznymi, drugie – zewnętrznymi. Dane wewnętrzne są gromadzone i przechowywane na potrzeby zarządzania urządzeniami. Należą do nich opisy zasad funkcjonowania urządzenia jak np. przepisy, książki obsługi, instrukcje dotyczące demontażu urządzeń, bieżąca rejestracja zdarzeń np. rejestr: kosztów eksploatacji urządzeń, zużycia paliwa, wypracowane resursy do remontu, częstotliwość występowania awarii na godzinę nalotu itp., spisy np. ilości statków powietrznych, zapasowych części płatowca lub silnika w magazynie oraz korespondencja przedsiębiorstwa eksploatującego statki powietrzne. W przypadku danych zewnętrznych ich zakres nie zależy od urządzenia, dla którego sporządzana jest prognoza. Rozróżnia się dane zewnętrzne dotyczące otoczenia bliższego i dalszego. Dane dotyczące otoczenia bliższego są tworzone przez urządzenia bezpośrednio powiązane z urządzeniem prognozowanym. Jeśli urządzeniem, dla którego sporządza się prognozę jest statek powietrzny, to jego otoczenie bliższe stanowią dostawcy urządzeń zapasowych i klienci wykorzystujący statki powietrzne. Dane dotyczące otoczenia dalszego to przede wszystkim instytucje krajowe i międzynarodowe typu ustawodawczego i gospodarczego oraz gospodarka krajowa i światowa. Przedsiębiorstwo eksploatujące statki powietrzne jest zainteresowane takimi danymi jak: ustawy, uchwały, czy też wielkość wydobycia ropy naftowej, co jest związane z ceną paliwa. W takim przypadku wszelkie konflikty zbrojne powodujące wzrost cen paliwa na giełdzie światowej zmuszają użytkowników statków powietrznych do podjęcia konkretnych działań poprzez wzrost cen biletów bądź ograniczenie wykonywanych lotów. Istotny wpływ może mieć również wzrost cen energii elektrycznej. W takim przypadku wzrastają koszty przechowywania paliwa. Należy w tym miejscu zwrócić uwagę na koszty zbierania, przetwarzania i przechowywania danych. Celowe wydaje się stwierdzenie, że należy gromadzić tylko te dane, które wnoszą coś

nowego do oceny zjawiska, jednocześnie podnosząc jakość prognozy formułowanej na ich podstawie. Powinny one być gromadzone według określonych kryteriów, które przedstawiono na rys 3.4.



Rys. 3.4: Kryteria stosowane podczas selekcji danych.

Dane uważa się za rzetelne, gdy nie występują w nich błędy: losowe i systematyczne. W pierwszym przypadku błędy są wynikiem omyłkowego wpisania przy zbieraniu lub przetwarzaniu danych. W drugim przypadku błędy mogą wynikać z celowego fałszowania danych, np. w celu ukrycia faktycznego stanu technicznego urządzeń podaje się inną niż w rzeczywistości częstotliwość występowania usterek. O ile w przypadku błędów losowych kontrola pozwala na wyeliminowanie powstałych błędów o tyle w przypadku błędów systematycznych jest to utrudnione. Należy wykonać wykresy, na których łatwo dostrzec obserwacje nietypowe. W przypadku statków powietrznych nietypowe może się okazać gwałtowne zmniejszenie ilości awarii przy jednoczesnej populacji statków powietrznych i jednoczesnej wartości nalotu w danym roku.

Dane powinny być jednoznacznie rozumiane. Na przykład, stwierdzenie „pracochłonność w przedsiębiorstwie eksploatującym statki powietrzne w 2005 roku wyniesie 550 godzin” nie jest jednoznaczne, gdyż pojęcie pracochłonności może być różnie interpretowane jako pracochłonność obsługi reśursowych, remontów itp.

W przypadku statków powietrznych pracochłonność napraw można określić stosunkiem liczby przepracowanych godzin do liczby eksploatowanych statków powietrznych, bądź osób wykonujących remont. Ponadto pracochłonność remontów może być wyrażona liczbą godzin przeznaczonych na remont do liczby godzin spędzonych w powietrzu podczas bezawaryjnej pracy urządzenia. Świadczy to o identyfikowalności zjawiska przez zmienną lub zmienne.

W danych powinny być zawarte wszystkie ważne wiadomości wystarczające do rozpoznania problemu. Wiadomości powtarzające się i marginesowe powinny być pomijane.

Decydującą rolę prognosty jest określenie, który z czynników działających w przeszłości na zjawisko będzie odgrywał znaczącą rolę w przyszłości. Co więcej ważne jest również określenie siły oddziaływania czynnika na zjawisko. Ponadto w przyszłości może się pojawić nowy czynnik.

Jak wspomniano wcześniej użytkownikowi urządzeń zależy na zmniejszeniu kosztów zbierania, przetwarzania i przechowywania danych. Są one tym wyższe im większy jest zbiór danych. W takim przypadku celowe jest dążenie do minimalizacji danych, natomiast pozyskiwanie tylko tych, które w znaczący sposób mogą poprawić jakość uzyskiwanych prognoz.

Porównywalność danych może być rozważana pod kątem różnych czynników, np. m.in.: (i) czasu: jednakowy odstęp czasu między obserwacjami zmiennych o charakterze zasobów; (ii) terytorium: jednakowe terytorium np. państwa bądź okręgu – województwa eksploatującego statki powietrzne w całym okresie objętym badaniem; (iii) pojęć i kategorii: te same definicje, klasyfikacje, metody obliczeń: np. zużycia środków trwałych itp. Należy liczyć się z tym, że wraz z upływem czasu zmieniają się zjawiska i nasza wiedza o nich, co prowadzi do nieuchronnych zmian w rejestracji danych, stosowanych definicji oraz metod obliczeń. Trzeba zdawać sobie sprawę z tego, czy można danym zawierzyć, czy wnioski wyciągnięte na podstawie ich analizy odnoszą się do przedmiotu badań oraz czy nie są istotnie zniekształcone z powodu niepełności danych.

3.3. Prognozowanie szeregów czasowych


Szeregi czasowe są zbiorem obserwacji następujących po sobie w czasie. W przypadku gdy obserwacji zjawiska dokonuje się co pewien okres czasu, taki szereg nazywa się dyskretnym, natomiast jeśli zbiór zawiera informacje ciągłe nazywa się go ciągłym. Zazwyczaj dane tworzące szeregi czasowe muszą być uporządkowane chronologicznie tworząc szereg czasowy zapisywany jako funkcja $y(t)$ czasu t .

W większości szeregów czasowych $y(t)$ można wyróżnić składową systematyczną i składową przypadkową. Pierwsza z nich jest wynikiem oddziaływania stałego zestawu czynników na zmienną badaną i składa się z trendu, sezonowości i składowej periodycznej. Składowa przypadkowa jest wynikiem wahań przypadkowych lub zakłóceń i utrudnia identyfikację struktury zjawiska.

Trend stanowi długookresową skłonność do jednokierunkowych zmian, czyli zniżkową lub zwyżkową tendencję rozwojową. Należy zaznaczyć, że może on być wyznaczony, gdy dysponuje się długim ciągiem obserwacji prognozowanych zmiennych. Im dłuższy jest badany okres czasu tym wyciągnięte wnioski są bardziej precyzyjne. Wyróżnia się następujące rodzaje trendów: liniowe, wykładnicze i gasnące (rys.3.5).

Pracochłonność usuwania awarii może przejawiać rosnący trend liniowy (np., co roku pracochłonność rośnie średnio o 100 godzin), wzrost wykładniczy (np., co roku pracochłonność rośnie o 10%) lub trend gasnący (w pierwszych latach pracochłonność

rośnie o 100 godzin, w drugim roku wzrost wynosi 90% poprzedniego roku tzn. $100 \times 0,9 = 90$ godzin, itp.).




Rys. 3.5: Poszczególne typy trendów: liniowy, wykładniczy i gasnący.

Wahania sezonowe mają skłonność do powtarzania się w ściśle określonych okresach czasu, nieprzekraczających jednego roku. Jeżeli szereg zachowuje się w sposób okresowy z okresem s , tzn. że po tym okresie czasu będzie wykazywał podobne właściwości. Długość cyklu wahań może zależeć od charakteru badanego zjawiska. W badaniach empirycznych najczęściej obserwuje się roczny cykl wahań. Aby można było zaobserwować wahania o rocznym cyklu, szereg czasowy musi składać się z obserwacji krótszych niż rok, np. półrocznych, kwartalnych, miesięcznych [Cie2001]. Na przykład pracochłonność usuwania awarii może osiągać minimum zimą lub latem (związane jest to z intensywnością wykonywania lotów). Reguła ta może powtarzać się z roku na rok, chociaż względna wielkość spadku zimą może się zmieniać z roku na rok. Składniki sezonowe w takim przypadku mogą być:

- a) addytywne: np. pracochłonność wykonywania remontów rośnie co roku w marcu o 30 godzin, aby uwzględnić to wahanie sezonowe należałoby dodać do prognoz co roku w miesiącu marcu 30 godzin, natężenia wzrostów i spadków wartości badanej zmiennej wokół linii trendu są generalnie jednakowe,
- b) multiplikatywne: w marcu pracochłonność może wzrosnąć o 20%, zatem jeśli pracochłonność jest duża, to bezwzględny wzrost pracochłonności będzie proporcjonalnie większy, i znów w tym przypadku pracochłonność wzrośnie o pewien czynnik, a więc składnik sezonowy jest multiplikatywny i wynosi 1,2, w modelu multiplikatywnym sezonowość łączy się z tendencją rozwojową przez

mnożenie, gdyż wahania sezonowe są w tym przypadku proporcjonalne do wielkości tendencji rozwojowej.



Rys. 3.6: Sezonowość addytywna i multiplikatywna.

Wahania cykliczne wyrażają się w postaci długookresowych, rytmicznych wahań wartości zmiennej wokół stałego, przeciętnego poziomu lub wokół trendu tej zmiennej [Kop2002]. Wahania cykliczne charakteryzują się dłuższym okresem niż wahania sezonowe, w niektórych przypadkach o zmiennym w czasie okresie.

Wahania przypadkowe, nazywane zakłóceniami w intensywności wykonywania lotów spowodowane są nieprzewidywanymi i występującymi sporadycznie zdarzeniami, takimi jak nieprawidłowo wykonane remonty statków powietrznych, katastrofy lotnicze – powodujące czasowe zawieszenie wykonywania lotów czy konflikty zbrojne – np. atak terrorystyczny w dniu 11 września 2001 roku na World Trade Center. Na podstawie dodatkowych danych można wyodrębnić zakłócenia w szeregu czasowym, jednak ich predykcja nie jest możliwa.

Wyodrębnienie składowych trendu, sezonowości i wahań przypadkowych z badanego szeregu pozwala na poprawienie jakości przewidywań, dlatego też dąży się do ich wyodrębnienia i pomiaru. Uzyskuje się to za pomocą dekompozycji szeregu, której cel i sposób zostanie opisany w jednym z następnych podrozdziałów pracy.

3.4. Metody wyrównywania szeregów czasowych

Przed przystąpieniem do prognozowania w wielu przypadkach bardzo ważne jest wyrównanie szeregu czasowego. Służy do tego kilka metod, których użycie wynika z zastosowanej metody prognozowania. Aby uzyskać prawidłową i dokładną prognozę należy dopasować do szeregu właściwą metodę wyrównywania. Niektóre z metod wyrównywania szeregów czasowych przedstawiono na rys. 3.7.

Metodę średniej ruchomej N – punktową, nazywaną również metodą mechaniczną, stosuje się w przypadku, gdy w szeregu występują oprócz normalnych składowych bardzo duże wahania przypadkowe. Wartości zmiennej prognozowanej są zastępowane średnimi arytmetycznymi, obliczanymi z nieparzystej lub parzystej liczby kolejnych wyrazów szeregu. Jeżeli liczba wyrazów średniej ruchomej jest nieparzysta, wtedy średnia ruchoma zostaje wycelowana przez obliczenie średniej każdej pary kolejnych średnich

niecentrowanych. Metoda ta stosowana jest również do prognozowania, przy czym przyjmuje się, że wartość zmiennej prognozowanej w następnym okresie jest równa średniej arytmetycznej z k ostatnich wartości z tej zmiennej [Cie2001]. Ponadto w prognozowanym szeregu czasowym nie powinna występować tendencja rozwojowa i wahania sezonowe.



Rys. 3.7: Metody wyrównywania szeregów czasowych.

Model średniej ruchomej określany jest przez:

$$y_t^* = \frac{1}{k} \sum_{i=t-k}^{t-1} y_i, \quad (3.8)$$

gdzie: y_t^* - prognoza zmiennej Y wyznaczona na okres t ,

y_t - wartość zmiennej prognozowanej w okresie t ,

k - liczba wyrazów średniej ruchomej, nazywana stałą wygładzania.

Stała wygładzania określona jest przez prognozę. Średnia ruchoma wyznaczona z większej liczby wyrazów silniej wygładza szereg, jednak wolniej reaguje na zmiany poziomu prognozowanej zmiennej. Mniejsza liczba wyrazów szybciej odzwierciedla zmiany zachodzące w wartościach prognozowanej zmiennej, natomiast wynikiem jest mniejszy efekt wygładzania szeregu i większy wpływ wahań przypadkowych. Do wyznaczenia liczby wyrazów średniej ruchomej używa się średniego kwadratowego błędu prognozy ex post, z którego wartość pierwiastka wyraża odchylenie prognoz wygasłych od wartości zmiennej prognozowanej, określonego wzorem:

$$s^* = \frac{1}{n-k} \sum_{i=k+1}^n (y_i - y_i^*)^2, \quad (3.9)$$

gdzie: y_t^* - prognoza zmiennej Y wyznaczona na okres t ,

y_t - wartość zmiennej prognozowanej w okresie t ,

n - liczba wyrazów szeregu czasowego zmiennej prognozowanej,
 k - stała wygładzania.

Minimalny średniokwadratowy błąd prognozy określa wartość k .

Innym modelem, uwzględniającym fakt, że nowsze dane zawierają bardziej aktualne informacje jest model średniej ruchomej ważonej:

$$y_t^* = \sum_{i=t-k}^{t-1} y_i w_{i-t+k+1}, \quad (3.10)$$

gdzie: y_t^* - prognoza zmiennej Y wyznaczona na okres t ,
 y_i - wartość zmiennej prognozowanej w okresie i ,
 $w_{i-t+k+1}$ - waga nadana przez prognozę wartości zmiennej prognozowanej w okresie i ,
 k - stała wygładzania.

W modelu średniej ruchomej ważonej nowszym informacjom nadaje się relatywnie większe wagi niż obserwacjom starszym. Zadaniem prognozy jest więc określenie liczby wyrazów średniej oraz wagi nadawane poszczególnym wyrazom szeregu.

W przypadku pojawienia się tendencji rozwojowej, stosuje się model podwójnej średniej ruchomej, nazywany również modelem liniowej średniej ruchomej. Polega on na podwójnym wygładzeniu szeregu, najpierw średnią ruchomą prostą lub ważoną, a następnie powtórny wygładzeniu metodą średniej ruchomej.

Innym sposobem wyrównania szeregu jest zastosowanie mediany N - punktowej. Każdy punkt przekształconego szeregu jest obliczony jako mediana N - sąsiednich punktów. Jeśli N jest nieparzyste, to ruchoma mediana zostaje naturalnie wycelowana w środku okna mediany ruchomej. Natomiast, gdy N jest parzyste, to mediana ruchoma zostaje naturalnie wycelowana przez obliczenie średniej każdej pary kolejnych niewycelowanych median.

Niezwykłą precyzję uzyskuje się przy zastosowaniu metody trendu pełzającego. Propozycję i metodę wykorzystania trendu pełzającego można znaleźć w [Dit2000]. Wyrównywanie szeregu czasowego y_1, \dots, y_n należy rozpocząć od ustalenia stałej wygładzania k , gdzie ($k < n$). Na podstawie kolejnych fragmentów szeregu:

$$\begin{array}{l} y_1, \dots, y_k, \\ y_2, \dots, y_{k+1}, \\ \dots\dots\dots\dots\dots\dots \\ y_{n-k+1}, \dots, y_n, \end{array} \quad (3.11)$$

szacuje się parametry liniowych funkcji trendu.

Jeżeli będą to funkcje:

$$\begin{aligned}
f_1(t) &= a_1 + b_1 t && \text{dla } 1 \leq t \leq k, \\
f_2(t) &= a_2 + b_2 t && \text{dla } 2 \leq t \leq k+1, \\
&\dots\dots\dots && \dots\dots\dots \\
f_{n-k+1}(t) &= a_{n-k+1} + b_{n-k+1} t && \text{dla } n-k+1 \leq t \leq n,
\end{aligned}
\tag{3.12}$$

to dla dowolnego t ($1 \leq t \leq n$) wartościom y_t odpowiadają wygładzone wartości (teoretyczne wartości) otrzymywane za pomocą niektórych spośród przedstawionych wyżej funkcji $f_j(t) = a_j + b_j t$ ($j = 1, \dots, n-k+1$). Są to funkcje, dla których:

$$d(t) \leq j \leq g(t), \tag{3.13}$$

gdzie:

$$d(t) = \begin{cases} 1 & \text{dla } t = 1, \dots, k, \\ t - k + 1 & \text{dla } t = k + 1, \dots, n. \end{cases}$$

$$g(t) = \begin{cases} 1 & \text{dla } t = 1, \dots, n - k + 1, \\ n - k + 1 & \text{dla } t = n - k + 2, \dots, n. \end{cases}$$

Ostatecznym wygładzeniem są średnie wszystkich takich wygładzeń, tzn.:

$$\bar{y}_t = \frac{1}{1 + g(t) - d(t)} \sum_{j=d(t)}^{g(t)} f_j(t), \quad t = 1, 2, \dots, n. \tag{3.14}$$

Natomiast, aby otrzymać wykres trendu szeregu czasowego w postaci funkcji segmentowej, nazywanej trendem pełzającym, należy połączyć kolejne punkty (t, \bar{y}_t) .

W celu ekstrapolacji modelu w przyszłość, należy zastosować metodę wag harmonicznym, polegającą na [Cie2001]:

a) obliczeniu przyrostów funkcji trendu według:

$$w_{t+1} = \bar{y}_{t+1} - \bar{y}_t, \quad t = 1, \dots, n-1. \tag{3.15}$$

b) określeniu średniej przyrostów:

$$\bar{w} = \sum_{t=1}^{n-1} C_{t+1}^n w_{t+1}, \tag{3.16}$$

gdzie C_{t+1}^n są wagami harmonicznymi realizującymi postulat postarzania informacji. Wagi są liczbami, których suma wynosi 1, najstarsze mają najmniejsze znaczenie, natomiast najnowsze największe. Wagi są liczbami należącymi do przedziału $(0, 1]$, a ich konstrukcja jest następująca:

$$C_{t+1}^n = \frac{1}{n-1} \sum_{i=1}^t \frac{1}{n-i}, \quad t = 1, \dots, n-1. \quad (3.17)$$

- c) wyznaczeniu odchylenia standardowego przyrostów trendu pełzającego, ważonych wagami harmonicznymi:

$$s_w = \left[\sum_{i=1}^{n-1} C_{i+1}^n (w_{i+1} - \bar{w})^2 \right]^{0.5}, \quad (3.18)$$

- d) następnie należy „dokleić” do ostatniego punktu trendu pełzającego (n, \bar{y}_n) prostą o nachyleniu \bar{w} przez co dokonuje się ekstrapolacji trendu. Prognozę punktową na okres T wyznacza się z:

$$y_T^* = \bar{y}_n + (T - n)\bar{w}, \quad (3.19)$$

- e) dla zadanej wiarygodności prognozy p konstruuje się przedział prognozy:

$$P\{y_T^* - u_T s_w \leq y_T \leq y_T^* + u_T s_w\} = p, \quad (3.20)$$

gdzie:
$$u_T = u \sum_{i=1}^{T-n} C_{n-i+1}^n, \quad n < T \leq 2n-1; \quad (3.21)$$

W zależności od rozkładów przyrostów trendu pełzającego wyznacza się współczynnik u , z tablic rozkładu normalnego lub z tablic t -Studenta. Natomiast rozpiętość przedziału prognozy jest uzależniona od:

- wiarygodności prognozy (p),
- rozkładu przyrostów trendu pełzającego,
- okresu, na który jest budowana prognoza im dalszego okresu dotyczy prognoza, tym u , jest większe.

Innym sposobem do wyrównania szeregu czasowego przed prognozowaniem jest zastosowanie filtra 4253H. To przekształcenie obejmuje kilkakrotne wygładzenie przy pomocy średniej/ mediany ruchomej szeregu czasowego. Podczas filtrowania dokonywane zostają następujące przekształcenia szeregu:

- a) 4 – wyrazowa mediana ruchoma wycentrowała przez dwuwyrazową medianę ruchomą,
- b) 5 – cio wyrazowa mediana ruchoma,
- c) 3 – wyrazowa mediana ruchoma,
- d) 3 – wyrazowa ważona średnia ruchoma przy zastosowaniu wag Hanninga (0.25;0.5;0.25),
- e) obliczenie reszt przez odjęcie przekształconego szeregu od szeregu pierwotnego,

- f) powtórzenie dla reszt przekształceń od a) do d),
- g) dodanie przekształconych reszt do przekształconego szeregu.

W wyniku zastosowania filtra 4253H uzyskuje się szereg wygładzony z jednoczesnym zachowaniem charakterystycznych własności szeregu pierwotnego.

Po dokonaniu wyrównania szeregu czasowego można przystąpić do prognozowania.

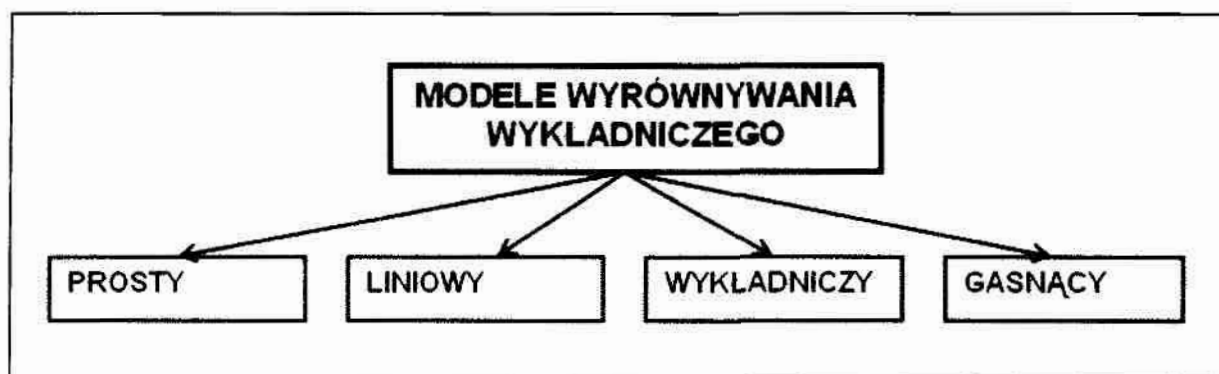
3.5. Metody wyrównywania wykładniczego

Rozwój metod wyrównywania wykładniczego nastąpił w latach pięćdziesiątych. Zasadniczą przyczyną było wprowadzenie komputerów do wykonywania obliczeń. Do jednych z pierwszych modeli należy zaliczyć [Sta1994]: model Browna (1950), model Holta (1952) i model Wintersa (1960). Wygładzanie wykładnicze stało się bardzo popularne jako metoda prognozowania dla wielu typów danych szeregów czasowych. Metoda ta została rozwinięta niezależnie przez Browna i Holta. Brown podczas II wojny światowej pracował dla Marynarki Wojennej USA, gdzie opracowywał system śledzący cel do lokalizacji okrętów podwodnych dla potrzeb sterowania ogniem. Technika ta została zastosowana później do prognozowania popytu na części zapasowe. Pomysły te zostały opisane w książce z 1959 r. na temat sterowania zapasami. Badania Holta były finansowane przez Oddział Badawczy Marynarki Wojennej. Holt rozwinął niezależnie modele wyrównywania wykładniczego dla procesów stabilnych, procesów z trendami liniowymi i dla danych sezonowych.

Gardner zaproponował dwuwymiarowy system klasyfikacji, rozważający różne modele w kategoriach sezonowości: brak, addytywna lub multiplikatywna oraz trendu: brak, liniowy, wykładniczy i gasnący. Po skojarzeniu czterech postaci trendu głównego i trzech rodzajów wahań okresowych (sezonowych) uzyskuje się dwanaście modeli wyrównywania wykładniczego.

Zadaniem prognosty jest wybranie jednego z dwunastu modeli, odpowiedniego ze względu na postać trendu i rodzaju wahań okresowych oraz określenie wartości odpowiedniego zestawu współczynników modelu (α , δ , γ , φ). Ponadto dla modeli ze składnikiem sezonowym, należy przeprowadzić dodatkowe analizy, co umożliwia określenie okresu τ wahań dominującej składowej harmonicznej. Dzięki zastosowaniu komputerów do wykonywania obliczeń w bardzo szybki sposób można określić odpowiednie współczynniki modelu. Wcześniej odbywało się to metodą prób i błędów.

Jak wspomiano w poprzednim podrozdziale przed przystąpieniem do prognozowania należy wygładzić szereg czasowy. Podczas wyrównywania wykładniczego badany szereg wygładza się za pomocą średniej ruchomej ważonej. Wagi są dobierane według prawa wykładniczego. Wyrównywanie wykładnicze może być oparte na różnych modelach, które przedstawiono na rys. 3.8. W celu ujednoczenia oznaczeń w równaniach, oraz algorytmu ich przekształcania skorzystano z [Cie2001].



Rys. 3.8: Modele wyrównywania wykładniczego.

Prosty model wyrównywania wykładniczego stosuje się, gdy w szeregu czasowym występuje prawie stały poziom zmiennej prognozowanej oraz wahania przypadkowe. W celu wyznaczenia prognozy na okres t należy skorzystać ze wzoru:

$$y_t^* = F_{t-1} = \frac{y_{t-1}}{k} - \frac{y_{t-k-1}}{k} + y_{t-1}^*, \quad (3.22)$$

gdzie: y_t^* - jest wartością prognozy;

$\frac{1}{k}$ - waga.

Jeśli zamiast wartości zmiennej prognozowanej w okresie $(t - k - 1)$ użyje się wartości przybliżonej – wartości prognozy wyznaczonej na poprzedni okres, można uzyskać równanie, w którym najnowszej obserwacji zmiennej prognozowanej nadana jest waga $\frac{1}{k}$, prognozie – waga $\left(1 - \frac{1}{k}\right)$, a konstrukcja równania jest następująca:

$$y_t^* = \frac{1}{k} y_{t-1} + \left(1 - \frac{1}{k}\right) y_{t-1}^*. \quad (3.23)$$

Po zastąpieniu symbolem α wagę $\frac{1}{k}$, otrzymuje się:

$$y_t^* = F_{t-1} = \alpha y_{t-1} + (1 - \alpha) y_{t-1}^*. \quad (3.24)$$

Parametr α nazywany jest również parametrem wygładzania i jest liczbą z przedziału $(0, 1]$. Jeśli jego wartość jest bliska jedności prognoza uwzględnia w bardzo wysokim stopniu błędy ex post prognoz poprzednich, natomiast gdy jest bliska zero, to prognoza w bardzo małym stopniu uwzględnia błędy poprzednich prognoz.

Jeśli za błąd ex post prognozy wyznaczonej na okres t tj. za wyrażenie $y_{t-1} - y_{t-1}^*$ podstawimy wyrażenie q_{t-1} , otrzymamy:

$$y_t^* = F_{t-1} = y_{t-1}^* + \alpha q_{t-1}. \quad (3.25)$$

Jeśli powyższe równanie rozwinie się poprzez zastąpienie prognozy wyznaczonej na okres $t-1$ (y_{t-1}^*) wyrażeniem $\alpha y_{t-2} + (1-\alpha)y_{t-2}^*$, to wynikiem jest równanie:

$$\begin{aligned} y_t^* &= \alpha y_{t-1} + (1-\alpha)[\alpha y_{t-2} + (1-\alpha)y_{t-2}^*] = \\ &= \alpha y_{t-1} + \alpha(1-\alpha)y_{t-2} + (1-\alpha)^2 y_{t-2}^*. \end{aligned} \quad (3.26)$$

Jeśli za y_{t-2}^* podstawimy się wyrażenie $\alpha y_{t-3} + (1-\alpha)y_{t-3}^*$, wynikiem będzie:

$$y_t^* = \alpha y_{t-1} + \alpha(1-\alpha)y_{t-2} + \alpha(1-\alpha)^2 y_{t-3}^*. \quad (3.27)$$

a następnie

$$\begin{aligned} y_t^* &= \alpha y_{t-1} + \alpha(1-\alpha)y_{t-2} + \alpha(1-\alpha)^2 y_{t-3}^* + \alpha(1-\alpha)^3 y_{t-4}^* + \\ &+ \alpha(1-\alpha)^4 y_{t-5}^* + \dots + (1-\alpha)^{t-1} y_1^*. \end{aligned} \quad (3.28)$$

Wszystkie wagi $\alpha \neq 1$ mają wartości wykładniczo malejące, stąd też pochodzi nazwa metody: wygładzanie wykładnicze. Prognoza na okres t jest równa prognozie wyznaczonej na okres poprzedni ($t-1$) skorygowanej o pewną część (α) jej bezwzględnego błędu ex post. Bardzo ważnym zadaniem prognosty przy tworzeniu modelu jest wybór wartości prognozy y_1^* . Najczęściej jest to wartość początkowa zmiennej prognozowanej (y_1) lub średnia arytmetyczna rzeczywistych wartości zmiennej prognozowanej z wybranej próbki (np. z 6. wyrazów). Dzięki zastosowaniu komputerów do obliczeń w bardzo krótkim czasie można uzyskać wartości średniego błędu prognoz wygasłych w zależności od różnych wartości α ($\alpha = 0,1; 0,2; 0,3; \dots; 1,0$). Niejednokrotnie błąd ten jest używany do oceny dopuszczalności prognoz.

Drugim z modeli wyrównywania wykładniczego jest **model liniowy Holta**. Stosuje się go do szeregów czasowych, w których występuje tendencja rozwojowa i wahania przypadkowe. Nazywany jest również dwuparametrycznym modelem Holta ze względu na występowanie dwóch parametrów. Równania modelu Holta mają następującą postać [Cie2001]:

$$F_{t-1} = \alpha y_{t-1} + (1-\alpha)(F_{t-2} + S_{t-2}), \quad (3.29)$$

oraz funkcja

$$S_{t-1} = \beta(F_{t-1} - F_{t-2}) + (1-\beta)S_{t-2}, \quad (3.30)$$

gdzie: F_{t-1} – wygładzona wartość zmiennej prognozowanej na okres $t-1$,

S_{t-1} – wygładzona wartość przyrostu trendu na okres $t-1$,
 α, β – parametry modelu o wartościach z przedziału $[0, 1]$.

W równaniu (3.29) w odróżnieniu od równania (3.23) opisującego model prostego wyrównywania wykładniczego dodano do członu F_{t-1} (przyjmowanego w prostym wyrównywaniu wykładniczym za prognozę y_t^*) oceny przyrostu trendu w okresie $t-1$. Algorytm postępowania przy konstrukcji równania (3.30) jest taki sam jak w przypadku równania (3.23). Różnica $F_{t-1} - F_{t-2}$ przyjmowana za najnowszą ocenę przyrostu trendu jest ważona przez parametr β , poprzednia zaś ocena przyrostu trendu S_{t-2} przez $(1 - \beta)$.

Równanie na okres $t > n$ jest następujące:

$$y_t^* = F_n + (t - n)S_n, \quad t > n \quad (3.31)$$

gdzie: y_t^* – prognoza zmiennej Y wyznaczona na okres t ,
 F_n – wygładzona wartość zmiennej prognozowanej dla okresu n ,
 S_n – ocena przyrostu trendu na okres n ,
 n – liczba wyrazów szeregu czasowego zmiennej prognozowanej.

Układ równań (3.29) – (3.30) można przedstawić również jako:

$$F_{t-1} = F_{t-2} + S_{t-2} + \alpha q_{t-1} = y_{t-1}^* + \alpha y_{t-1}, \quad (3.32)$$

oraz

$$S_{t-1} = S_{t-2} + \alpha \beta q_{t-1}, \quad (3.33)$$

gdzie: $q_{t-1} = y_{t-1} - y_{t-1}^*$.

Podobnie jak w przypadku modeli prostego wyrównywania wykładniczego zadaniem prognosty jest określenie początkowej wartości F (F_1) i dodatkowo S (S_1). Niejednokrotnie, za F_1 przyjmuje się pierwszą wartość zmiennej prognozowanej: y_1 , a za S_1 przyjmuje się różnicę $y_2 - y_1$. Niektórzy autorzy prognoz proponują za początkowe wartości F_1 i S_1 przyjąć: wyraz wolny oraz współczynnik kierunkowy liniowej funkcji trendu oszacowanej na podstawie próbki wstępnej. Ponadto jak można zauważyć model liniowy Holta jest wyposażony „dodatkowo” w parametr $\beta \in (0, 1)$ w porównaniu z prostym wyrównywaniem wykładniczym. Jeśli wartość β wynosi 0, składnik trendu jest stały dla wszystkich wartości szeregu czasowego i dla wszystkich prognoz. W takim przypadku, przy obliczaniu wartości wyrównywanych i prognoz, założone zostaje stałe nachylenie linii trendu. Jeśli wartość β wynosi 1, wtedy składnik trendu zostaje zmodyfikowany z obserwacji na obserwację przez odpowiedni błąd prognozy, nachylenie jest przeliczane dla

każdej obserwacji na podstawie odpowiedniej bezpośrednio poprzedzającej wartości wyrównanej. Wtedy nachylenie nie jest stałe i zmienia się z obserwacji na obserwację, co przybliży wartości obserwowane. Głównym zadaniem prognozy jest przeprowadzenie eksperymentów z wykorzystaniem odpowiedniego oprogramowania komputera, co ułatwia wybór najwłaściwszej kombinacji parametrów α oraz β . Elementem porównania różnych kombinacji może być średni błąd prognoz wygasłych, który obliczany jest ze wzoru:

$$y_t^* = F_{t-1} + S_{t-1}, \quad 2 \leq t \leq n. \quad (3.34)$$

Liniowy model Holta może być stosowany do prognozowania popytu na części zamienne (jak wspomniano na początku podrozdziału) statków powietrznych. Ponieważ popyt na określone części zamienne może wolno rosnąć z upływem czasu lub maleć (składnik trendu) a trend może się wolno zmieniać (ze względu na starzenie się statków powietrznych lub wycofywanie ich z eksploatacji) niekiedy celowe wydaje się zastosowanie tego modelu w takim przypadku.

Jeśli prognozowany szereg czasowy zawiera tendencję rozwojową, wahania sezonowe oraz wahania przypadkowe stosuje się **model Wintersa**. Addytywna wersja modelu jest opisana równaniami:

$$F_{t-1} = \alpha(y_{t-1} - C_{t-1-r}) + (1-\alpha)(F_{t-2} - S_{t-2}), \quad (3.35)$$

$$S_{t-1} = \beta(F_{t-1} - F_{t-2}) + (1-\beta)S_{t-2}, \quad (3.36)$$

$$C_{t-1} = \gamma(y_{t-1} - F_{t-1}) + (1-\gamma)C_{t-1-r}. \quad (3.37)$$

podczas gdy multiplikatywna wersja modelu przyjmuje następującą postać:

$$F_{t-1} = \alpha \frac{y_{t-1}}{C_{t-1-r}} + (1-\alpha)(F_{t-2} + S_{t-2}), \quad (3.38)$$

$$S_{t-1} = \beta(F_{t-1} - F_{t-2}) + (1-\beta)S_{t-2}, \quad (3.39)$$

$$C_{t-1} = \gamma \frac{y_{t-1}}{F_{t-1}} + (1-\gamma)C_{t-1-r}, \quad (3.40)$$

gdzie: F_{t-1} – jest wygładzoną wartością zmiennej prognozowanej w okresie $t - 1$, po eliminacji wahań sezonowych;

S_{t-1} – jest oceną przyrostu trendu na okres $t - 1$;

C_{t-1} – jest oceną wskaźnika sezonowości na okres $t - 1$;

r – reprezentuje liczbę faz cyklu – długość cyklu sezonowego;

α, β, γ – są parametrami modelu, przyjmującymi wartości z przedziału $[0, 1]$.

Aby obliczyć czyste wskaźniki sezonowości C należy:

- wyodrębnić tendencję rozwojową z szeregu poprzez określenie modelu trendu dla prognozowanej zmiennej,
- wyeliminować tendencję rozwojową;

- dla modelu addytywnego przez obliczenie różnic wartości rzeczywistych prognozowanej zmiennej i wartości teoretycznych otrzymanych z modelu tendencji rozwojowej:

$$z_{it} = y_{it} - \hat{y}_t \quad (3.41)$$

- dla modelu multiplikatywnego przez wyznaczenie ilorazów rzeczywistych wartości prognozowanej zmiennej przez odpowiadające im wartości teoretyczne otrzymane z modelu tendencji rozwojowej:

$$z_{it} = \frac{y_{it}}{\hat{y}_t} \quad (3.42)$$

Obliczone wielkości według wzorów (3.41) i (3.42) zawierają wahania sezonowe i przypadkowe.

- c) aby „pozbyć” się wahań przypadkowych oblicza się surowe wskaźniki sezonowości, którymi są wielkości średnie wyznaczone na podstawie wielkości z_{it} , dotyczące tej samej fazy cyklu wahań:

$$z_i = \frac{1}{k} \sum_{j=0}^{k-1} z_{i+j \times r, j} \quad (3.43)$$

gdzie: k - jest liczbą jednoimiennych faz w badanym szeregu czasowym.

Według [Cie2001] do wyznaczenia tych wskaźników stosuje się średnią arytmetyczną lub medianę.

- d) ostatnim etapem jest obliczenie czystych wskaźników sezonowości c , które liczy się dla modelu addytywnego ze wzoru:

$$c_i = z_i - q, \quad (3.44)$$

dla modelu multiplikatywnego:

$$c_i = \frac{z_i}{q}, \quad (3.45)$$

gdzie: $q = \frac{1}{r} \sum_{i=1}^r z_i$.

Czyste wskaźniki sezonowości podają natężenie wahań sezonowych w poszczególnych fazach cyklu. Dla modelu addytywnego suma ich powinna być równa zero, natomiast dla multiplikatywnego liczbie faz tworzących cykl.

Równanie prognozy na okres $t > n$ dla modelu Wintersa – wersja addytywna przyjmuje następującą postać:

$$y_t^* = F_n + S_n(t-n) + C_{t-r}, \quad (3.46)$$

oraz wersja multiplikatywna:

$$y_t^* = [F_n + S_n(t - n)]C_{t-r}, \quad (3.47)$$

gdzie: n – jest liczbą wyrazów szeregu czasowego zmiennej prognozowanej.

Zadaniem prognosty jest zarówno dobór początkowych wartości F_t , S_t , C_t , ..., C oraz dobór wartości parametrów wygładzania α , β oraz γ . W literaturze problemu można spotkać wiele propozycji dotyczących wyboru typowych wartości parametrów modelu Wintersa. Należy wziąć pod uwagę szybkość zmiany poszczególnych składowych szeregu czasowego. Jeśli zmiany następują niezbyt szybko to wartości parametrów wygładzania α , β i γ ustala się na poziomie bliskim zera, w przeciwnym wypadku na poziomie bliskim jedności. Podobnie jak w przypadku opisanych powyżej modeli wyrównywania najlepszym rozwiązaniem jest przeprowadzenie serii eksperymentów z wykorzystaniem komputera i wybór takiej kombinacji wartości parametrów, przy której średni kwadratowy błąd prognoz wygasłych osiąga wartość minimalną, dla prognoz z jednookresowym wyprzedzeniem (wg. wzoru 3.34).

Według [Cie2001] za wartości początkowe F_t , S_t , C_t , ..., C można przyjąć:

- a) *średnią z wartości zmiennej w cyklu lub pierwszą wartość zmiennej prognozowanej (y_1),*
- b) *różnicę średnich wartości zmiennej wyznaczonych dla drugiego i pierwszego cyklu, lub różnicę drugiej i pierwszej wartości zmiennej prognozowanej, tj. $y_2 - y_1$,*
- c) *wyznaczoną na podstawie szeregu czasowego średnia różnic (dla modelu addytywnego) lub ilorazów (dla modelu multiplikatywnego), odpowiadających tej samej fazie cyklu sezonowego, wartości zmiennej prognozowanej i wygładzonych wartości trendu.*

W modelu Wintersa w odróżnieniu od wcześniej przedstawionych modeli występuje dodatkowo parametr wygładzania γ , służący do wyrównania składnika sezonowości. Ma on tylko zastosowanie do modeli sezonowych. Jeśli parametr γ ma wartość 1 to składnik sezonowości jest przeliczany z obserwacji na obserwację, jeśli natomiast γ ma wartość 0, to w obliczeniach wartości wyrównywanych i prognoz uwzględnia się stały stabilny składnik sezonowości.

Model z **trendem gasnącym** jest rozwinięciem modelu liniowego jednak prognozy są "wzmocnione" przez składnik trendu gasnącego. Parametr ϕ jest parametrem modyfikacji trendu i określa on, jak silnie zmiany trendu wpłyną na estymatory trendu dla kolejnych prognoz, to znaczy, jak szybko trend zostanie "wygaszony" lub jak szybko wzrośnie. W celu obliczenia wyrównanych wartości dla pierwszego sezonu, konieczne są wartości początkowe składników sezonowych. Do obliczenia wyrównanej wartości (prognozy) dla

pierwszej obserwacji szeregu konieczne są obie oceny S_1 i T_1 (trend początkowy), które dla modelu addytywnego obliczane są jako:

$$T_1 = \frac{1}{\phi} \cdot \frac{M_k - M_1}{(k-1) \cdot p}, \quad (3.48)$$

$$S_1 = M_1 - \frac{p \cdot T_1}{2}, \quad (3.49)$$

gdzie: ϕ - jest parametrem wyrównywania;
 k - jest liczbą pełnych cykli sezonowych;
 M_k - jest średnią dla ostatniego cyklu sezonowego;
 M_1 - jest średnią dla pierwszego cyklu sezonowego;
 p - jest długością cyklu sezonowego.

Wzór na wyrównaną wartość prognozy dla pierwszej obserwacji szeregu jest następujący:

$$F_1 = S_1 + T_1 \cdot \phi + C_1. \quad (3.50)$$

Dla kolejnych wartości wykorzystywane są wzory:

$$S_t = (S_{t-1} + T_{t-1}) + \alpha \cdot (y_{t-1} - F_{t-1}), \quad (3.51)$$

$$T_t = \phi \cdot [(S_t - S_{t-1}) + (1 - \delta) \cdot T_{t-1}] \quad (3.52)$$

$$F_t = S_t + T_t \cdot \phi + C_t. \quad (3.53)$$

Wartość parametru C znana jest dla pierwszego cyklu sezonowości. Dla $t > L$ we wzorze F na wartość prognozy w miejsce C podstawia się wartość wyrównanego wykładniczo wskaźnika sezonowości S_w . Oblicza się go w zależności od t :

a) dla $L < t < 2L$

$$S_{w(t)} = C_{t-L} + \delta \cdot (1 - \alpha) \cdot (y_{t-L} - F_{t-L}), \quad (3.54)$$

b) dla $t > 2L$

$$S_{w(t)} = S_{w(t-L)} + \delta \cdot (1 - \alpha) \cdot (y_{t-L} - F_{t-L}). \quad (3.55)$$

W przypadku prognozy zmianie ulega wzór na wskaźnik sezonowości S_t :

$$S_t = S_{t-1} + T_{t-1}. \quad (3.56)$$

Dla modelu multiplikatywnego S_1 i T_1 oblicza się w ten sam sposób co dla modelu addytywnego, natomiast wzór na wyrównaną wartość prognozy dla pierwszej obserwacji szeregu jest następujący:

$$F_1 = (S_1 + \phi \cdot T_1) \cdot C_1. \quad (3.57)$$

Dla kolejnych wartości wskaźnik sezonowości oblicza się jako:

$$S_t = \alpha \cdot T_{t-1} + S_{t-1} + \frac{(1-\alpha)(y_{t-1} - F_{t-1})}{C_{t-1}}. \quad (3.58)$$

Ze względu na brak wartości parametru y_{t-l} dla prognoz wykorzystuje się wzory:

$$S_t = \alpha \cdot T_{t-1} + S_{t-1}, \quad (3.59)$$

$$T_t = \phi \cdot (S_t - S_{t-1}) + \frac{T_{t-1} \cdot (1-\phi)}{C_{t-1}}, \quad (3.60)$$

$$F_t = (S_t + \phi \cdot T_t) \cdot C_t. \quad (3.61)$$

Czysty wskaźnik sezonowości C ma zastosowanie tylko przy pierwszym cyklu sezonowości. Dla pozostałych L zastępuje się go S_w , który oblicza się ze wzorów:

a) dla $t > L$:

$$S_{w(t)} = C_{t-1} + \frac{\delta \cdot (1-\alpha) \cdot (y_{t-L} - F_{t-L})}{S_{t-L}}, \quad (3.62)$$

b) dla $t > 2L$:

$$S_{w(t)} = S_{w(t-L)} + \frac{\delta \cdot (1-\alpha) \cdot (y_{t-L} - F_{t-L})}{S_{t-L}}. \quad (3.63)$$

3.5.1. Dekompozycja szeregu czasowego

Celem dekompozycji sezonowej jest wyodrębnienie składników szeregu czasowego: trendu, sezonowości, wahań cyklicznych i składnika losowego. W literaturze problemu wyróżnia się dwa typy dekompozycji sezonowej:

- a) klasyczna metoda dekompozycji sezonowej (nazywana Census I);
- b) metoda dekompozycji sezonowej Census X-11 (udoskonalenie metody Census I).

Wykorzystując do obliczeń pakiet komputerowy STATISTICA 5.0 PL, zauważa się połączenie trendu i wahań cyklicznych w jedną całość zwaną składnikiem wahań długookresowych i trendu (trend – cykl, TC_t). Szczegółowa zależność funkcyjna pomiędzy składnikami szeregu czasowego może przybierać różne formy. Dwie najprostsze z nich polegają na tym, że składniki szeregu łączą się:

a) addytywnie, co można wyrazić przy pomocy wzoru:

$$x_t = TC_t + S_t + \varepsilon_t, \quad (3.64)$$

b) multiplikatywnie:

$$x_t = T_t \cdot C_t \cdot S_t \cdot \varepsilon_t, \quad (3.65)$$

gdzie: x_t – jest wartością obserwowaną szeregu czasowego w czasie t ,
 S_t – jest sezonowością,
 ε_t – jest to składnik losowy.

Różnice pomiędzy addytywnym i multiplikatywnym składnikiem szeregu czasowego przedstawiono w podrozdziale 3.2.

Algorytm obliczeń przy wykorzystaniu dekompozycji sezonowej Census I według [Sta1994] jest następujący:

- a) oblicza się średnią ruchomą dla szeregu czasowego o długości równej długości okresowi wahań co pozwala na wyeliminowanie składnika sezonowego oraz pozostałej zmienności wynikającej z wahań o okresach krótszych w szeregu składającym się ze średniej ruchomej,
- b) wyodrębnia się składnik sezonowy i składnik losowy – nieregularny, w przypadku modelu addytywnego, odejmuje się od szeregu empirycznego wartości średniej ruchomej; natomiast w modelu multiplikatywnym należy podzielić wartości szeregu empirycznego przez wartości średniej ruchomej,
- c) oblicza się wskaźnik sezonowy, w modelach addytywnych jest reprezentowany przez średnią; natomiast w modelach multiplikatywnych – średnią środkową, czyli średnią po wyeliminowaniu najmniejszej i największej wartości dla każdego punktu w sezonie,
- d) eliminuje się wahania sezonowe, poprzez odjęcie od pierwotnego szeregu dla modeli addytywnych lub podzielenie w modelach multiplikatywnych przez wskaźnik sezonowości, a szereg wynikowy jest szeregiem skorygowanym sezonowo, czyli został usunięty z niego składnik sezonowy,
- e) wyodrębnia się składnik wahań długookresowych i trendu (trend – cykl, TC), składnik cykliczny różni się od składnika sezonowego tym, że zwykle jest dłuższy niż jeden sezon, a różne cykle mogą mieć różną długość, dlatego też, połączony wskaźnik trendu i wahań cyklicznych należy aproksymować przez zastosowanie do pięciowyrazowej ważonej średniej ruchomej o wagach $1, 2, 3, 2, 1$ do szeregu, z którego wyeliminowano wahania sezonowe,
- f) następnie można wyodrębnić składnik losowy - błąd poprzez odjęcie składnika opisującego wahania długookresowe w modelach addytywnych lub podzielenie szeregu skorygowanego w modelach multiplikatywnych przez ten składnik.

Metoda Census II była rozwijana przez lata w Amerykańskim Biurze Spisów Powszechnych. Jednak największą popularność zdobył tak zwany wariant X – 11 metody Census II. Poniżej przedstawiono niektóre poprawki Metody Census II w stosunku do Census I:

- a) różne miesiące mają nierównomierną liczbę dni oraz różną liczbę dni roboczych. W przypadku remontów statków powietrznych, większa liczba dni wolnych jak soboty, niedziele może mieć wpływ na ilość godzin spędzonych w danym miesiącu przy usuwaniu awarii, wariant X – 11 metody Census II umożliwia użytkownikowi przetestowanie, czy taka zmienność ze względu na dni robocze występuje w szeregu i pozwala na dokonanie odpowiedniej korekty,
- b) niektóre szeregi czasowe zawierają informacje „odstające”, to znaczy ekstremalne wahania spowodowane rzadkimi zdarzeniami, na przykład wypadek lotniczy i związana z tym przerwa w wykonywaniu lotów może wpłynąć na ilość wykonywania lotów w danym miesiącu, a poprzez zastosowanie tzw. „kontroli statycznej” istnieje możliwość wyeliminowania lub zmodyfikowania obserwacji „odstających” poniżej lub powyżej określonego zakresu (wyrażonego przez wielokrotność odchylenia standardowego),
- c) istnieje możliwość ponownego oszacowania czynnika sezonowości, mającego na celu zwiększenie jego dokładności, oszacowaniu podlega również trend, wahania cykliczne oraz niewyeliminowany składnik losowy; w efekcie końcowym, po zastosowaniu kilkakrotnych poprawek można uzyskać lepsze estymatory składników.

Jak wspomniano na początku podrozdziału, zastosowanie pakietu STATISTICA 5.0, ułatwia użytkownikowi otrzymanie wszystkich wyników w bardzo krótkim czasie.

3.5.2. Periodogram

Innym sposobem analizy szeregów czasowych jest założenie, że szereg zbudowany jest z podstawowych funkcji sinusoidalnych: sinus i cosinus o określonych długościach fali. W celu zbadania struktury harmonicznej szeregu czasowego należy dokonać jego analizy widmowej. W wyniku analizy widmowej można odkryć w szeregu czasowym kilka cykli okresowych o różnych długościach, które na początku wyglądały na mniej lub bardziej losowy szum.

W wielu przypadkach, użytkownika nie interesują wartości współczynników przy funkcji sinus lub cosinus. Do wykrywania i estymacji składowej sinusowej, o znanej częstotliwości, zaburzonej przez szum używa się periodogramu. Bardzo ważny jest przede wszystkim okres, który jest wyznaczony za pomocą największej wartości periodogramu. Periodogram otrzymuje się po zsumowaniu kwadratów współczynników dla każdej częstotliwości. Jest to związane z faktem, że funkcje sinus i cosinus są wzajemnie niezależne (ortogonalne). Obliczenia periodogramu dokonuje się w sposób następujący

[Box1983]. Jeśli przyjmiemy model szeregu Fouriera, w którym liczba obserwacji $N=2q+1$ jest nieparzysta:

$$y_t = a_0 + \sum_{i=1}^q (a_i c_{it} + \beta_i s_{it}) + e_t, \quad (3.66)$$

$$\text{gdzie: } c_{it} = \cos 2\pi f_i t, \quad (3.67)$$

$$s_{it} = \sin 2\pi f_i t, \quad (3.68)$$

$$f_i = \frac{i}{N} \quad \text{- i-ta składowa harmoniczna częstotliwości podstawowej } 1/N.$$

Estymatory współczynników a_0 i (a_i, β_i) metodą najmniejszych kwadratów są równe:

$$a_0 = \bar{y}, \quad (3.69)$$

$$a_i = \frac{2}{N} \sum_{t=1}^N y_t c_{it}, \quad i = 1, 2, \dots, q, \quad (3.70)$$

$$b_i = \frac{2}{N} \sum_{t=1}^N y_t s_{it}. \quad (3.71)$$

Periodogram składa się z $q=(N-1)/2$ wielkości, a intensywność I przy częstotliwości f_i wynosi:

$$I(f_i) = \frac{N}{2} (a_i^2 + b_i^2), \quad i = 1, 2, \dots, q. \quad (3.72)$$

Jeśli N jest parzyste, tzn. $N=2q$, to wzory (3.69), (3.70), (3.71) i (3.72) stosuje się dla $i = 1, 2, \dots, q-1$, natomiast dla $i = q$ wzory są następujące:

$$a_q = \frac{1}{N} \sum_{t=1}^N (-1)^t y_t, \quad (3.73)$$

$$b_q = 0, \quad (3.74)$$

w takim przypadku intensywność I przy częstotliwości f_i wynosi:

$$I(f_q) = I(0,5) = N a_q^2. \quad (3.75)$$

Największa częstotliwość jest równa 0,5 cykła na jednostkę czasu, ponieważ okres jest równy 2 jednostkom.

Okres T funkcji sinus lub cosinus definiuje się jako długość czasu potrzebnego na jeden pełny cykl. Zatem jest to odwrotność częstotliwości:

$$T = \frac{1}{f_i}. \quad (3.76)$$

3.6. Metoda ARMA i ARIMA

Metodologia ARIMA została rozwinięta przez Boxa i Jenkinsa. Nazywana jest metodą Boxa – Jenkinsa. Skrót ARIMA pochodzi od nazwy w języku angielskim (autoregressive integrated moving average process, czyli scałkowany proces autoregresji i średniej ruchomej). Modele ARIMA są nazywane również modelami autoregresji i średniej i są stosowane do modelowania szeregów stacjonarnych czyli takich, w których występują jedynie wahania okresowe wokół średniej lub niestacjonarnych, sprowadzanych do stacjonarnych. Są one pochodną modeli ARMA, w których zakłada się stacjonarność procesu. Niestacjonarne szeregi są sprowadzane do stacjonarnych poprzez d – krotne obliczanie różnic sąsiednich wyrazów szeregu np. $(y_t - y_{t-1})$, następnie $(y_t - y_{t-1})^2$, itp.

Stosowanie modeli ARIMA wymaga od prognosty dysponowania długim szeregiem czasowym. Według [Box1983] minimalna liczba obserwacji potrzebna do zastosowania tych modeli wynosi 50. Jeżeli ilość danych jest mniejsza niż 50, należy skorzystać z doświadczenia i informacji o przeszłości dla otrzymania wstępnych modeli. Modele te można korygować w miarę napływania danych. Ponadto, ARIMA jest techniką złożoną, nie jest łatwa w użyciu oraz wymaga dużego doświadczenia od prognosty. Jest to związane z tym, że struktura wielu szeregów czasowych często jest niewyraźna, wariancja składnika losowego jest znaczna, a prognosta powinien odkryć nie tylko ukryty wzorzec, ale również generować prognozy.

Wyróżnia się trzy podstawowe rodzaje modeli należące do tej grupy:

- a) autoregresji – AR, ARI,
- b) średniej ruchomej – MA, IMA,
- c) mieszane (autoregresji i średniej ruchomej) – ARMA, ARIMA.

W modelu autoregresji AR zakłada się, że występuje autokorelacja pomiędzy wartościami zmiennej prognozowanej a jej wartościami opóźnionymi w czasie. Ponadto można oszacować współczynniki modelu, które opisują kolejne elementy szeregu na podstawie opóźnionych w czasie poprzednich elementów. Jego postać jest następująca:

$$y_t = \varphi_0 + \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + e_t, \quad (3.77)$$

gdzie: $y_1, y_{t-1}, \dots, y_{t-p}$ - jest wartością zmiennej prognozowanej w okresie

$$t, t-1, \dots, t-p;$$

$\varphi_0, \varphi_1, \dots, \varphi_{t-p}$ - są parametrami modelu,

e_t - jest to błąd (reszta) dla okresu t ,

p - wielkość opóźnienia.

Wartość szeregu czasowego y_t jest, więc sumą składnika losowego e_t oraz kombinacji liniowej poprzednich obserwacji. Jak wspomniano wcześniej, w przypadku modelu AR istnieje wymóg stacjonarności, a niestacjonarność procesu może się objawiać na wiele sposobów. Proces autoregresyjny jest stabilny, jeśli parametry należą do pewnego zakresu. Jeśli na przykład jest tylko jeden parametr autoregresyjny, to powinien się on znaleźć w przedziale $-1 < \varphi_1 < +1$. W innym przypadku efekty przeszłe akumulowałyby się, a wartości kolejnych y_t – ów zmierzałyby do nieskończoności (przebiegałyby zgodnie z krzywą wykładniczą), czyli szereg byłby niestacjonarny [Sta1984].

Niezależnie od procesu autoregresyjnego, każdy element szeregu może pozostawać pod wpływem realizacji składnika losowego w okresach przeszłych, który to wpływ nie może być wyjaśniony przez składnik autoregresyjny. W takim przypadku, postać modelu średniej ruchomej MA:

$$y_t = \theta_0 + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}, \quad (3.78)$$

gdzie: y_t – jest wartością zmiennej prognozowanej w okresie t ,

$e_t, e_{t-1}, \dots, e_{t-q}$ – błędy (reszty) modelu w okresach $t, \dots, t - q$,

$\theta_0, \theta_1, \dots, \theta_q$ – są parametrami modelu,

q – wielkość opóźnienia.

W modelu średniej ruchomej każda obserwacja składa się ze składnika losowego ε , oraz kombinacji liniowej składników losowych z przeszłości. Według [Dit2000/1] nazwa „średnia ruchoma” jest powszechnie stosowana, pomimo tego, że wagi $1, -\theta_1, -\theta_2, \dots, -\theta_q$ nie muszą sumować się do jedności. Co więcej nie muszą być również dodatnie.

W wyniku połączenia modelu autoregresji i modelu średniej ruchomej uzyskuje się model ARMA, który czasami lepiej można dopasować do rozpatrywanego szeregu, a który jest opisany za pomocą:

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + e_t + \theta_0 - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}. \quad (3.79)$$

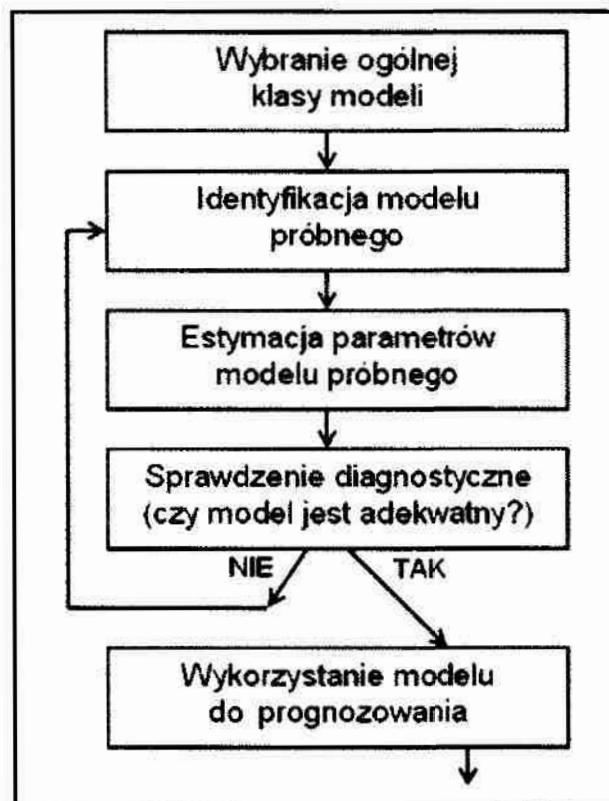
W modelu ARMA wartość zmiennej prognozowanej w okresie t zależy od jej poprzednich wartości, od różnic tych wartości oraz od różnic między poprzednimi wartościami rzeczywistymi zmiennej prognozowanej a jej wartościami uzyskanymi z modelu (tzn. od błędów prognoz).

Jeśli podczas rozpatrywania szeregu zmiennej prognozowanej okazuje się, że szereg nie jest stacjonarny dokonuje się operacji różnicowania. *Polega to na d – krotnym obliczeniu różnic sąsiednich wyrazów szeregu. Pierwsze różnice są obliczane jako $y_t - y_{t-1}$, drugie jako $(y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) = y_t - 2y_{t-1} + y_{t-2}$, trzecie i następne w podobny sposób. Postępuje się tak d – krotnie, dopóki uzyskany szereg różnic nie będzie szeregiem stacjonarnym. Budowane modele dla przekształconych szeregów, określa się odpowiednio*

do modeli (3.77) – (3.79) mianem zintegrowanych modeli: autoregresji ARI, średniej ruchomej IMA oraz autoregresji i średniej ruchomej ARIMA [Dit2000/1].

Modele ARIMA są opisywane przy użyciu notacji (p, d, q) , gdzie p oznacza rząd autoregresji (wielkość opóźnienia), d – krotność różnicowania, q – liczbę parametrów θ_i (wielkość opóźnienia) średniej ruchomej. Na przykład model ARIMA o parametrach $(0, 0, q)$ oznacza model średniej ruchomej o opóźnieniu q , model ARIMA o parametrach $(p, 0, q)$ to inaczej mieszany model autoregresji i średniej ruchomej ARMA o opóźnieniach p i q , a model ARIMA o parametrach $(p, d, 0)$, równoznaczny z modelem ARI (p, d) jest modelem autoregresji rzędu p dla szeregu czasowego po przeprowadzeniu operacji d – krotnego różnicowania.

Jak wspomniano wcześniej, wymaga się od szeregu czasowego aby był stacjonarny, to znaczy, powinien on mieć stałą w czasie średnią, wariancję i autokorelację. Autokorelacja oznacza korelację szeregu z nim samym, przesuniętym o określoną wartość opóźnienia k obserwacji. Dlatego zazwyczaj szereg wymaga różnicowania, aż do osiągnięcia stacjonarności (często wymaga to także przekształcenia logarytmicznego danych w celu ustabilizowania wariancji). W celu określenia koniecznego poziomu różnicowania, należy przeanalizować wykres danych i autokorelogram. Szczegółowy opis postępowania można znaleźć w [Han1989].



Rys. 3.9: Etapy iteracyjnego podejścia do budowania modeli [Box1983].

Sposób podejścia do budowania modeli ARIMA przedstawiono na rys 3.9. *Na podstawie teorii i praktyki należy wybrać odpowiednią klasę modeli. Ponieważ klasa ta jest zbyt obszerna dla bezpośredniego dopasowania do danych, rozważa się zgrubne metody identyfikacji podklasy tych modeli. Takie metody identyfikacji modeli, wykorzystując dostępne dane oraz znajomość układu, sugerują odpowiednią oszczędną podklasę modeli, którą można wypróbować. Oprócz tego, proces identyfikacji może być wykorzystany dla otrzymania zgrubnych wstępnych oszacowań parametrów modelu [Box1983].*

Wybór odpowiedniej klasy modeli należy dokonać przy pomocy autokorelogramu. Na autokorelogramie jest przedstawiona graficznie i liczbowo funkcja autokorelacji (ACF), to znaczy współczynniki autokorelacji i ich błędy standardowe dla kolejnych opóźnień w określonym zakresie opóźnień (np. 1 do 25). Podczas analizowania autokorelogramów należy pamiętać, że autokorelacje dla kolejnych opóźnień są formalnie zależne. Rozważmy następujący przykład. Jeśli pierwszy element jest ściśle związany z drugim, a drugi z trzecim, to pierwszy element musi być także do pewnego stopnia związany z trzecim itd. Oznacza to, że struktura autokorelacji może się poważnie zmienić po wyeliminowaniu autokorelacji pierwszego rzędu tzn. po różnicowaniu szeregu z opóźnieniem równym 1.

Inna użyteczna metoda badania struktury autokorelacji szeregu polega na analizie funkcji autokorelacji cząstkowych (PACF) - rozwinięcia autokorelacji, w którym została usunięta zależność od elementów pośrednich (tych wewnątrz opóźnienia). Innymi słowy autokorelacja cząstkowa jest podobna do autokorelacji, z wyjątkiem tego, że podczas jej obliczania autokorelacje z wszystkimi elementami w ramach opóźnienia zostają wyeliminowane. Jeśli opóźnienie zostało określone na 1 tzn. nie ma żadnych elementów pośrednich wewnątrz opóźnienia, to autokorelacja cząstkowa jest równoważna autokorelacji. W pewnym sensie autokorelacja cząstkowa dostarcza "czystszy" obrazu zależności dla poszczególnych opóźnień, czyli nie jest uwikłana w inne zależności szeregowo.

Wielkość opóźnień p i q określa się przez badanie statycznej istotności wyznaczonych współczynników autokorelacji cząstkowej [Dit2000/1].

W tabelach 3.1 – 3.5 przedstawiono podstawowe rodzaje modeli w zależności od przebiegu funkcji autokorelacji ACF oraz autokorelacji cząstkowej PACF [Han1989]. Z wykresów przedstawionych w tabelach wynika, że model z jednym parametrem autoregresyjnym AR(1) stosuje się jeśli wykres funkcji ACF opada wykładniczo, natomiast dla funkcji PACF występuje maksimum przy opóźnieniu 1 oraz brak jest korelacji dla innych opóźnień. Model z dwoma parametrami autoregresyjnymi AR(2) stosuje się gdy ACF ma kształt sinusoidalny lub występuje kombinacja zaników wykładniczych, a przy PACF występują duże wartości przy opóźnieniach 1 i 2 oraz brak jest korelacji dla innych opóźnień.

Tabela 3.1: Wykresy funkcji ACF i PACF w przypadku modelu autoregresji AR(1).

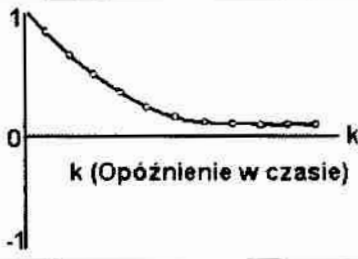
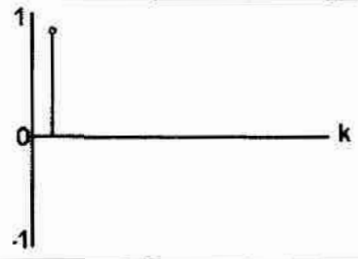
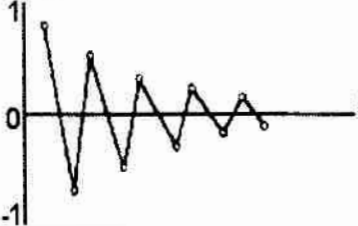

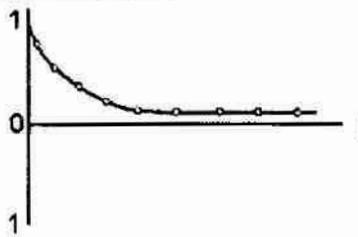
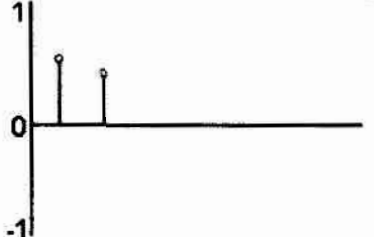
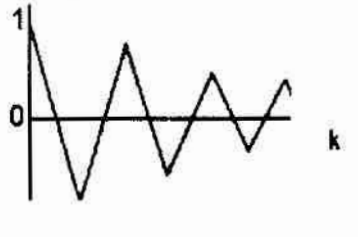
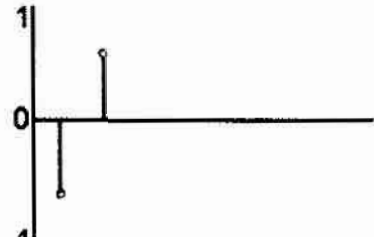
Model autoregresji: $AR(1): y_t = \varphi_0 + e_t + \varphi_1 y_{t-1}$	
Autokorelacja	Autokorelacja cząstkowa
 <p>k (Opóźnienie w czasie)</p>	
	

Tabela 3.2: Wykresy funkcji ACF i PACF w przypadku modelu autoregresji AR(2).

Model autoregresji: $AR(2): y_t = \varphi_0 + e_t + \varphi_1 y_{t-1} + \varphi_2 y_{t-2}$	
Autokorelacja	Autokorelacja cząstkowa
	
	

Jeden parametr średniej ruchomej MA(1) stosuje się gdy ACF osiąga maksimum przy opóźnieniu 1, brak jest korelacji dla innych opóźnień, a PACF gaśnie wykładniczo. Dwa parametry średniej ruchomej MA(2) stosuje się gdy ACF osiąga duże wartości przy opóźnieniach 1 i 2, brak jest korelacji dla innych opóźnień, natomiast PACF ma kształt sinusoidy lub występuje kombinacja zaników wykładniczych.

Tabela 3.3: Wykresy funkcji ACF i PACF w przypadku modelu średniej ruchomej MA(1).




Tabela 3.4: Wykresy funkcji ACF i PACF w przypadku modelu średniej ruchomej MA(2).





Tabela 3.5: Wykresy funkcji ACF i PACF w przypadku modelu średniej ruchomej ARIMA (1,1).



Model mieszany ARIMA (1,1), czyli jeden parametr autoregresyjny i jeden parametr średniej ruchomej należy zastosować wtedy, gdy ACF opada wykładniczo począwszy od opóźnienia 1, a PACF opada wykładniczo począwszy od opóźnienia 1. Wskazane jest, aby wypróbować modele alternatywne przy tych samych danych.

Model próbny zostaje dopasowany do danych, a jego parametry zostają wyestymowane. Zgrubne oszacowania, otrzymane na etapie identyfikacji, mogą być teraz użyte jako wartości początkowe w bardziej dokładnych iteracyjnych metodach estymacji parametrów.

Sprawdzenie diagnostyczne zastosowane zostaje w celu wykrycia możliwych niezgodności w dopasowaniu modelu i ew. podania ich przyczyn. Jeżeli niezgodności takie nie występują, model jest gotowy do wykorzystania. Jeżeli wykryta zostaje jakaś

niezgodność, powtarza się iteracyjny cykl identyfikacji, estymacji i sprawdzania diagnostycznego aż do znalezienia odpowiedniego modelu [Box1983].

Tabela 3.6: Przykładowe modele ARIMA.

Model	Opis modelu
(p, d, q)	ARIMA (model niesezonowy): p – oznacza rząd autoregresji (wielkość opóźnienia), d – oznacza krotność różnicowania, q – oznacza liczbę parametrów θ_i (wielkość opóźnienia) średniej ruchomej.
$(p, 0, 0)$	AR (p) – model autoregresji rzędu p .
$(0, 0, q)$	MA (q) – model średniej ruchomej z opóźnieniem q .
$(p, 0, q)$	ARMA (p, q) – model mieszany autoregresji rzędu p i średniej ruchomej z opóźnieniem q .
$(p, d, 0)$	ARI (p, d) – model autoregresji rzędu p dla szeregu czasowego po przeprowadzeniu d – krotnej operacji różnicowania.
$(0, d, q)$	IMA (d, q) – model średniej ruchomej z opóźnieniem q po przeprowadzeniu d – krotnej operacji różnicowania.
$(p, d, q)(ps, ds, qs)$	ARIMA (model sezonowy): p – rząd autoregresji (wielkość opóźnienia), d – krotność różnicowania, q – liczba parametrów θ_i (wielkość opóźnienia) średniej ruchomej, ps – rząd autoregresji sezonowej, ds – krotność różnicowania sezonowego, qs – wielkość opóźnienia sezonowego.
$(0, 1, 2)(0, 1, 1)$	w modelu tym nie ma parametrów autoregresyjnych, są 2 niesezonowe parametry średniej ruchomej oraz 1 sezonowy parametr średniej ruchomej, a parametry te zostały oszacowane dla szeregu po jednokrotnym różnicowaniu przy opóźnieniu równym 1 i jednokrotnym różnicowaniu sezonowym.

W metodologii ARIMA wyróżnia się również modele sezonowe. Multiplikatywny sezonowy model ARIMA jest uogólnieniem i rozwinięciem metody przedstawionej powyżej dla szeregów, w których prawidłowości powtarzają się sezonowo w czasie. Oprócz parametrów niesezonowych, należy oszacować parametry sezonowe dla określonego opóźnienia (ustalonego w fazie identyfikacji). Podobnie jak w przypadku prostego modelu ARIMA, występują tutaj parametry: sezonowe autoregresyjne (ps), sezonowe różnicowe (ds) oraz sezonowe średniej ruchomej (qs). Przykładowe modele wraz z oznaczeniami przedstawiono w tabeli 3.6.

Opóźnienie sezonowe stosowane dla parametrów sezonowych dobiera się w fazie identyfikacji [Sta1994].

3.7 Błędy prognoz

Przy prognozowaniu rozróżnia się dwa rodzaje błędów: *ex ante* oraz *ex post*. Ocena błędów prognoz miernikami *ex ante* jest możliwa tylko dla prognoz, które opracowano wykorzystując model zjawiska, przedstawiony w postaci funkcyjnej $y(t)$ oraz znane są parametry struktury stochastycznej takiego modelu. Jeżeli model jest nieznanymi błędami prognozy należy ocenić posługując się miernikami *ex post*.

W przypadku błędów *ex post* określa się różnice e_t między rzeczywistymi obserwacjami y_t zjawiska, a obserwacjami wygładzonymi s_t , traktowanymi jako prognozy stanów znanych z przeszłości:

$$e_t = y_t - s_t \quad (3.80)$$

gdzie: e_t – błędy *ex post* ($t = 1, 2, \dots, n$),
 y_t – rzeczywiste obserwacje zjawiska,
 s_t – obserwacje wygładzone (traktowane jako prognozy stanów znanych z przeszłości).

Do najczęściej spotykanych mierników *ex post* błędów należą:

1) Średni błąd **ME** (Mean Error):

$$ME = \frac{1}{n} \sum_{t=1}^n (y_t - s_t), \quad (3.81)$$

2) Średni błąd bezwzględny **MAE** (Mean Absolute Error):

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - s_t|, \quad (3.82)$$

3) Błąd średniokwadratowy **MSE** (Mean Squared Error):

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - s_t)^2, \quad (3.83)$$

4) Średni błąd procentowy **MPE** (Mean Percentage Error):

$$MPE = \frac{1}{n} \sum_{t=1}^n \frac{y_t - s_t}{y_t}, \quad (3.84)$$

5) Średni bezwzględny błąd procentowy **MAPE** (Mean Absolute Percentage Error):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - s_t}{y_t} \right|, \quad (3.85)$$

6) Błąd standardowy **SE** (Standard Error):

$$SE = \sqrt{\frac{\sum_{t=1}^n (y_t - s_t)^2}{n}}, \quad (3.86)$$

7) Suma błędów kwadratowych **SSE** (Sum Squared Error). Oblicza się ją odpowiednio jako sumę lub średnią wartości kwadratu reszt. Jest to bardzo często wykorzystywany wskaźnik braku dopasowania w statystycznych procedurach dopasowania:

$$SSE = \sum_n (y_t - s_t)^2. \quad (3.87)$$

8) W przypadku modeli ARIMA wymagane jest aby sumy kwadratu reszt modelu były zminimalizowane. Jeśli model nie jest odpowiedni, w iteracyjnym procesie estymacji może się zdarzyć, że oceny parametrów staną się bardzo duże, i faktycznie niedopuszczalne. W takim przypadku, program przypisze sumie kwadratów bardzo dużą wartość SS, tak zwaną **wartość kary**. Zazwyczaj "skłania" to proces iteracyjny do przesunięcia parametrów z nieważnych zakresów. Jednak w niektórych przypadkach ta strategia się nie udaje i podczas procedury estymacji możemy zaobserwować bardzo duże wartości SS w kolejnych iteracjach. W takiej sytuacji należy starannie ocenić trafność modelu. Jeśli model zawiera wiele parametrów i być może składnik interwencyjny, należy próbować powtórnie z innymi wartościami początkowymi parametrów.

Według [Stę2002] błąd średniokwadratowy można rozłożyć na trzy składniki:

$$\begin{aligned} MSE &= \frac{1}{n} \sum_n (y_t - s_t)^2 = \frac{1}{n} \sum_n (y_t^2 - 2y_t s_t + s_t^2) = \frac{1}{n} \sum_n y_t^2 - 2 \frac{1}{n} \sum_n y_t s_t + \frac{1}{n} \sum_n s_t^2 = \\ &= \frac{1}{n} \sum_n y_t^2 - \bar{y}_t^2 + \bar{y}_t^2 - 2 \left[\frac{1}{n} \sum_n y_t s_t - \bar{y}_t \bar{s}_t + \bar{y}_t \bar{s}_t \right] + \frac{1}{n} \sum_n s_t^2 - \bar{s}_t^2 + \bar{s}_t^2 = \\ &= s_y^2 + \bar{y}_t^2 - 2(s_{ys} + \bar{y}_t \bar{s}_t) + s_s^2 + \bar{s}_t^2 = \\ &= s_y^2 + \bar{y}_t^2 - 2(r_{ys} s_y s_s + \bar{y}_t \bar{s}_t) + s_s^2 + \bar{s}_t^2 = s_y^2 + \bar{y}_t^2 - 2r_{ys} s_y s_s - 2\bar{y}_t \bar{s}_t + s_s^2 + \bar{s}_t^2 = \\ &= (\bar{y}_t - \bar{s}_t)^2 + s_y^2 - 2r_{ys} s_y s_s + s_s^2 = (\bar{y}_t - \bar{s}_t)^2 + s_y^2 + 2s_y s_s - 2s_y s_s - 2r_{ys} s_y s_s + s_s^2 = \\ &= (\bar{y}_t - \bar{s}_t)^2 + (s_y - s_s)^2 + 2s_y s_s - 2r_{ys} s_y s_s = \boxed{(\bar{y}_t - \bar{s}_t)^2 + (s_y - s_s)^2 + 2(1 - r_{ys}) \cdot s_y s_s} \quad (3.88) \end{aligned}$$

gdzie: \bar{y}_t, \bar{s}_t - wartości średnie szeregu obserwowanego y_t i wygładzonego s_t ,

s_y^2, s_s^2, s_{ys} - wariancje szeregu obserwowanego y_t i wygładzonego s_t oraz ich kowariancja,

s_y, s_s, r_{ys} - odchylenia standardowe szeregu obserwowanego y_t i wygładzonego s_t oraz współczynnik korelacji między wartościami y_t i s_t .

W celu uzyskania „udziałów” MSE należy podzielić równanie 3.88 obustronnie przez MSE:

$$1 = \frac{(\bar{y}_t - \bar{s}_t)^2}{MSE} + \frac{(s_y - s_s)^2}{MSE} + \frac{2(1 - r_{ys}) \cdot s_y s_s}{MSE}. \quad (3.89)$$

U_1 U_2 U_3

U_1 jest to miara tzw. błędu systematycznego, czyli przesunięcia (dryfu) wartości średnich prognozy względem obserwacji. Jest to miara obciążenia prognozy, której udział U_1 zwykle nie powinien przekraczać wartości 0,1 (10%). U_2 jest miarą rozbieżności między odchyleniami standardowymi prognozy i wartości obserwowanych. Wskaźnik ten operuje kwadratem różnic ($s_y - s_s$), więc zarówno niedostateczna jak i nadmierna zmienność prognoz (w stosunku do zmienności obserwacji) jest jednakowo niebezpieczna. Opracowuje się często prognozy, w których wykorzystuje się jedynie trend zjawiska, zaniebując pozostałe składowe (zmienność sezonową i składnik losowy). Zmienność takich prognoz jest wtedy wyraźnie mniejsza niż zmienność szeregu rzeczywistego, co wyraża się dużą wartością U_2 . Wartość udziału U_3 jest tym mniejsza, im współczynnik korelacji r_{ys} jest bliższy jedności. Wiedząc, że r_{ys} może osiągać jedność tylko dla wielkości zależnych liniowo i wprost proporcjonalnie, można zauważyć, że U_3 jest miarą niezgodności kierunków zmian szeregu obserwowanego y_t i wygładzonego s_t . Każdy przypadek niezgodności między kierunkiem zmian wartości obserwowanych (y_t, y_{t-1}) i wartości wygładzonych (s_t, s_{t-1}) zmniejsza wartość współczynnika korelacji r_{ys} i tym samym powiększa wartość udziału U_3 [Stę2002].

W celach analitycznych stosuje się współczynnik rozbieżności Theil'a, obliczany ze wzoru:

$$I^2 = \frac{\frac{1}{n} \sum_n (y_t - s_t)^2}{\frac{1}{n} \sum_n y_t^2} = \frac{\sum_n (y_t - s_t)^2}{\sum_n y_t^2} = \frac{\sum_n e_t^2}{\sum_n y_t^2} \quad (3.90)$$

Miernik ten przyjmuje wartość równą zero, gdy prognozy są idealnie trafne. Tożsamość Theil'a można zapisać jako sumę trzech współczynników składowych:

$$I^2 = \frac{MSE}{\frac{1}{n} \sum_n y_t^2} = \frac{(\bar{y}_t - \bar{s}_t)^2}{\frac{1}{n} \sum_n y_t^2} + \frac{(s_y - s_s)^2}{\frac{1}{n} \sum_n y_t^2} + \frac{2(1 - r_{ys}) \cdot s_y \cdot s_s}{\frac{1}{n} \sum_n y_t^2} = I_1^2 + I_2^2 + I_3^2, \quad (3.91)$$

gdzie: I_1^2 - jest miarą obciążenia predykcji,

I_2^2 - informuje o różnicach między zmiennością wartości obserwowanych y_t oraz prognozowanych s_t ,

I_3^2 - jest miarą niezgodności kierunków zmian szeregu obserwowanego y_t i prognozowanego s_t .

W celu uzyskania informacji o udziale poszczególnych przyczyn oraz łatwiejszej interpretacji składowych Theil'a w całkowitym błędzie prognozy można je wyrazić w postaci:

$$1 = \frac{I_1^2}{I^2} + \frac{I_2^2}{I^2} + \frac{I_3^2}{I^2} = \hat{I}_1^2 + \hat{I}_2^2 + \hat{I}_3^2, \quad (3.92)$$

gdzie: $\hat{I}_1^2, \hat{I}_2^2, \hat{I}_3^2$ - są względnymi współczynnikami rozbieżności i mogą być wyrażane w procentach.

Inną prostą i popularną miarą rzetelności modelu jest trafność prognoz generowanych na podstawie części danych, tak że prognozy mogą zostać porównane ze znanymi (pierwotnymi) obserwacjami. Dobry model jednak powinien nie tylko umożliwiać dostatecznie trafne prognozy, ale powinien także być możliwie nieskomplikowany a reszty nie powinny zawierać żadnych składników systematycznych (np. autokorelogram reszt nie powinien ujawnić żadnych zależności szeregowych). Kontrola poprawności modelu polega na:

- a) wykreśleniu reszt i poszukiwaniu trendów systematycznych,
- b) zbadaniu autokorelogramu reszt, w którym nie powinna wystąpić żadna autokorelacja reszt.

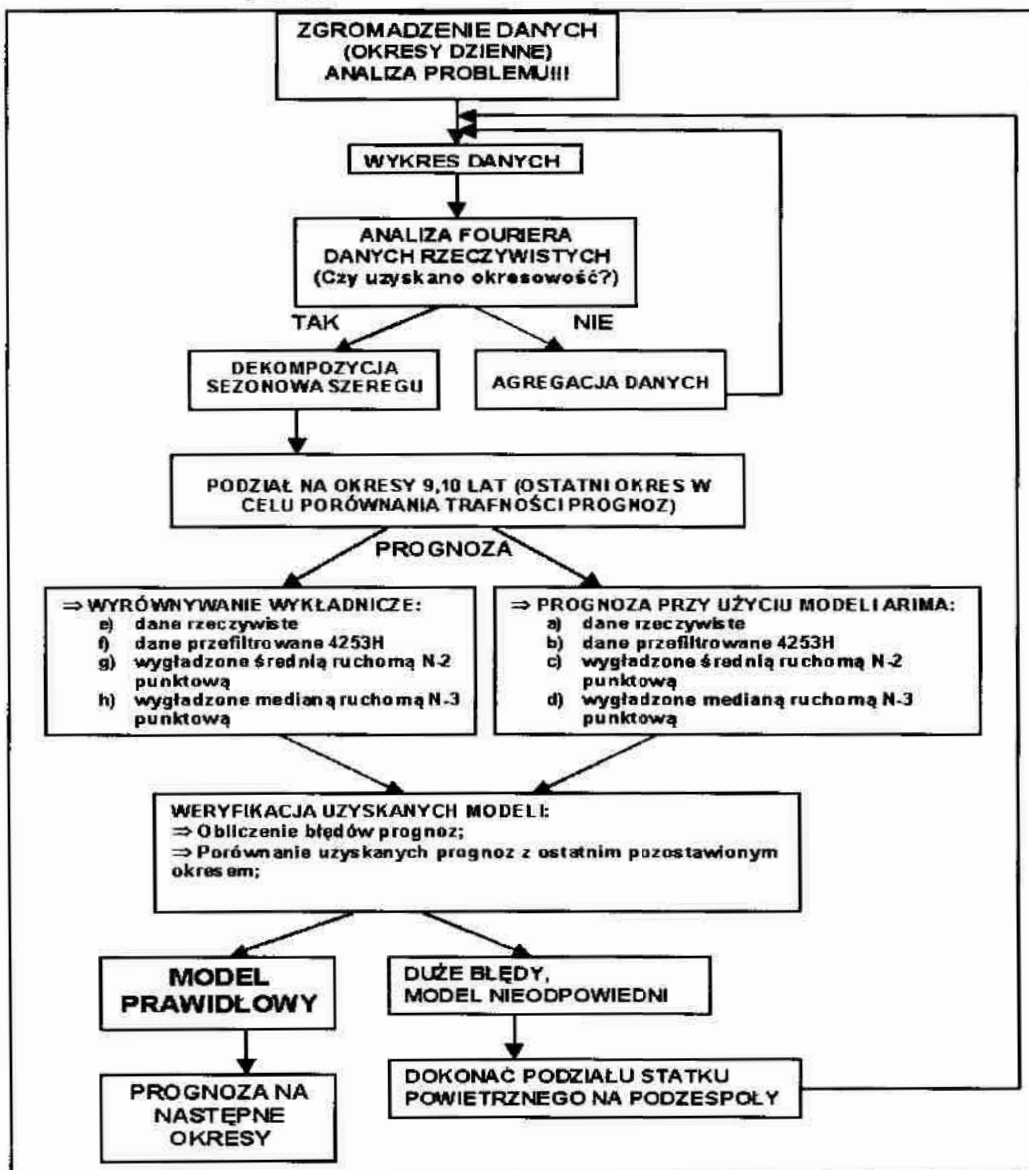
Oprócz przedstawionych powyżej mierników dokładności prognoz w literaturze można znaleźć dodatkowo trzy kolejne: procentowy błąd średniokwadratowy (MSPE), pierwiastek błędu średniokwadratowego (RMSE) oraz pierwiastek procentowego błędu średniokwadratowego (RMSPE). Opisy oraz przykłady zastosowań wymienionych mierników można znaleźć między innymi w [Acz2000], [Cze1980], [Now1998] oraz w [Wel1998].

ROZDZIAŁ 4

WYNIKI PROGNOZOWANIA METODAMI STATYSTYCZNYMI

4.1. Algorytm prognozowania stosowany w badaniach własnych

W literaturze problemu można znaleźć różne algorytmy, które można wykorzystać podczas prognozowaniu [Box1983]. Ze względu na potrzeby niniejszej pracy oraz z uwagi na zastosowane metody prognozowania, autor opracował własny algorytm prognozowania, który przedstawiono na rys. 4.1.



Rys. 4.1: Opracowany przez autora algorytm prognozowania pracochłonności napraw.

Przed przystąpieniem do prognozowania należy zgromadzić dane statystyczne i posegregować je w odpowiedni szereg czasowy (rys 2.8). Następnie przeanalizować problem, jaki wpływ na dane mogła mieć eksploatacja statków powietrznych, określić cel, jakiemu mają służyć prognozy i określić dopuszczalny błąd prognozy itp. Najlepszym sposobem określenia trafności prognoz jest porównanie ich z danymi rzeczywistymi, dlatego też celowe wydaje się podzielenie szeregu czasowego na okresy i pozostawienie ostatniego z nich do porównania wyników i obliczenia błędów prognozy. W literaturze problemu [Cie2000], [Dit2000/1] autorzy zalecają dokonywanie prognoz na jeden rok do przodu, jednak mając na uwadze konieczność wyznaczenia pracochłonności w następnym roku, prognozy zostaną przeprowadzone na następne 12 miesięcy. Następnie należy sporządzić wykres szeregu czasowego i określić okres. W tym celu stosuje się analizę widmową Fouriera, przedstawioną w podrozdziale 3.5.2. Do powyższych obliczeń można wykorzystać pakiet statystyczny STATISTICA. Okres zawarty w szeregu czasowym jest wyznaczony za pomocą największej wartości periodogramu. Jak wspomniano w poprzednim rozdziale niekiedy należy przygotować szereg czasowy poprzez jego wyrównanie. Umożliwia to wyodrębnienie m.in. okresu. W szeregu czasowym zastosowane zostanie wyrównywanie szeregu przy pomocy:

- a) średniej ruchomej 2 punktowej,
- b) mediany ruchomej 3 punktowej,
- c) filtra 4253H,
- d) prostego wyrównywania wykładniczego dla $\alpha = (0,1; 0,2; \dots; 0,9)$.

W przypadku braku możliwości określenia okresu (duża część brakujących danych), należy przeanalizować dane, następnie dokonać ich agregacji z okresów jednodniowych na dwudniowe, tygodniowe, dwutygodniowe itp. i powtórzyć kroki postępowania opisane powyżej. Mając wartość okresu można przystąpić do dekompozycji sezonowej. Celem jej jest wzrost precyzji modelowania w rezultacie wydzielenia składowych badanego szeregu. Po zakończeniu dekompozycji sezonowej należy poszukać najlepszych parametrów dla analizowanego modelu i przystąpić do prognozowania. Po uzyskaniu wyników należy porównać z danymi rzeczywistymi, obliczyć błędy prognoz i zweryfikować uzyskane modele. Jak wspomniano w poprzednim rozdziale niekiedy celowe jest sprawdzenie innych alternatywnych modeli: wyrównywania wykładniczego i modeli ARIMA. W przypadku braku satysfakcjonujących użytkownika wyników prognozy np. zbyt dużego błędu prognoz, należy poszukiwać innych przyczyn mających wpływ na szereg czasowy. W przypadku prognozy pracochłonności remontów wszystkich – „zsumowanych” podzespołów statku powietrznego, błędy mogą być zbyt duże. Podział statku powietrznego na podzespoły (rozdział 2), a następnie prognoza czasochłonności napraw poszczególnych podzespołów płatowca, osprzętu, silnika i URE niekiedy jest najlepszym rozwiązaniem.

Jedną z metod oceny jakości modelu opisującego szereg jest analiza szeregu reszt wyznaczonych pomiędzy wartościami rzeczywistymi i prognozowanymi. Ma ona na celu sprawdzenie [Tad2000]:

- czy prognozy generowane przez model nie są obciążone,
- czy średni błąd prognozy przyjmuje zbliżone wartości w całym badanym okresie czasu,
- czy kolejne wyrazy szeregu reszt nie są ze sobą skorelowane.


Po wykonaniu prognozy i uzyskaniu modelu celowe jest przedstawienie wartości reszt na wykresie w zależności od czasu. Reszty rozłożone równomiernie względem zera świadczą o modelu skonstruowanym prawidłowo, natomiast przewaga reszt ujemnych dowodzi o przeszacowaniu prognoz. Przewaga reszt dodatnich przemawia za tym, że prognozy są niedoszacowane. W celu weryfikacji nieobciążoności prognoz zaleca się wykonanie histogramu reszt. Reszty o rozkładzie normalnym i średniej równej zero cechują poprawnie skonstruowany model.

Istotne jest określenie braku występowania autokorelacji w szeregu reszt. Wzrokową ocenę autokorelacji przeprowadza się na podstawie wykresu słupkowego. Wysokość kolejnych słupków odpowiada wartości autokorelacji pomiędzy elementami szeregu oddalonymi od siebie o coraz większą liczbę okresów. W przypadku pojawienia się autokorelacji określonego rzędu należy dokonać ponownej analizy modelu.

4.2. Wyniki wyrównywania wykładniczego

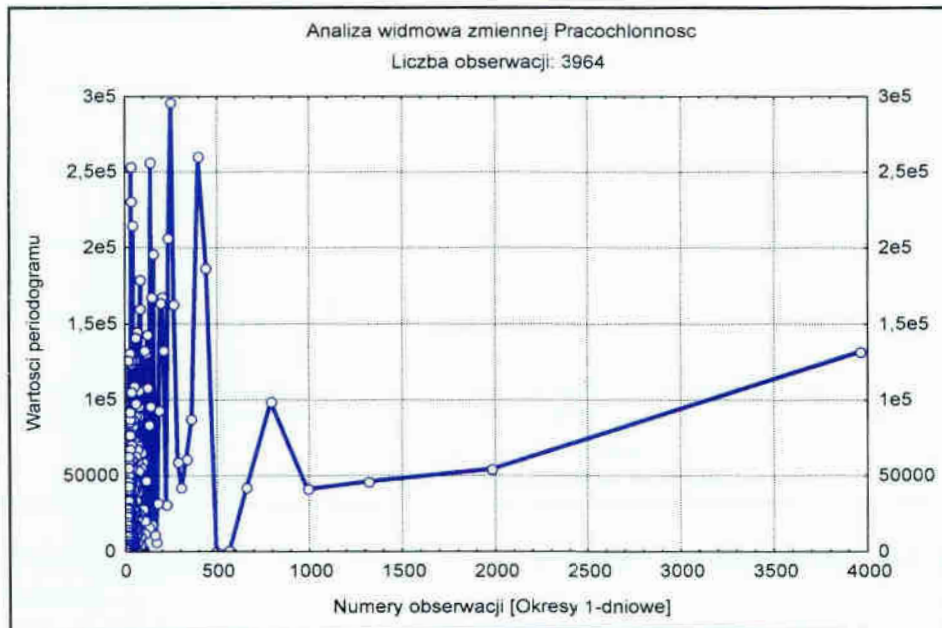
4.2.1. Wstępna analiza szeregu czasowego

Na rys. 4.2 przedstawiono zmienną Pracochłonność dla okresów 1 – dniowych, dotyczącą usuwania awarii wybranego typu statku powietrznego (36 sztuk eksploatowanych w jednym miejscu bazowania).



Rys. 4.2: Wykres zmiennej Pracochłonność – okresy 1- dniowe.

W celu wyodrębnienia okresu rozpoczęto od analizy widmowej Fouriera szeregu nie przekształconego.




Rys. 4.3: Wykres analizy widmowej zmiennej Pracochłonność [okresy 1 – dniowe].


Analiza potwierdziła przypuszczenia, że występuje duża nieciągłość szeregu i brak jest w nim prawidłowości. Przyczyną może być to, że aż 75% danych stanowią dni, w których nie były usuwane awarie. Jeżeli chodzi o pracochłonność wraz z upływem czasu wystąpiło mniej awarii o dużej pracochłonności. Niezauważalny jest również trend.

Zmienną pracochłonność poddano więc transformacji za pomocą filtra 4253H. Zastosowano metodę filtrowania 4253H, ponieważ jak wspomniano wcześniej tworzy ona szereg wygładzony z jednoczesnym zachowaniem charakterystycznych własności szeregu pierwotnego.

Ogólnym celem zastosowania technik wygładzania było "uwypuklenie" głównych systematycznych składowych szeregu czasowego poprzez wyeliminowanie mniejszych wahań, czyli szumu losowego. Wizualnie wynikiem wygładzania są przekształcenia ząbkowanego wzoru liniowego na bardziej gładką krzywą (rys. 4.4). Pomimo zastosowania filtra 4253H brak jest możliwości uzyskania szeregu, na podstawie którego można byłoby dokonać prognozy na okres następny. Niezbędne jest zastosowanie agregacji szeregu. Polega to na zsumowaniu pracochłonności napraw statków powietrznych z poszczególnych dni tygodnia. Celem jest wyodrębnienie okresu z badanego szeregu.




Rys. 4.4: Wykresy zmiennej Pracochłonność i zmiennej przekształconej filtrem 4253H [okresy 1 – dniowe].




Rys. 4.5: Wykres analizy widmowej zmiennej Pracochłonność przekształconej filtrem 4253H [okresy 1-dniowe].

Podzielono szereg na cykle (1,2,3) tygodniowe rozpoczynając od 1990 roku i cykle miesięczne, a następnie przystąpiono do analizy. Interesujące wyniki uzyskano po podzieleniu szeregu na okresy miesięczne (rys 4.6) Następnie przeprowadzono analizę Fouriera w celu wyznaczenia okresu po przekształceniu szeregu filtrem 4253H.



Rys. 4.6: Wykres zmiennej Pracochłonność po agregacji na okresy miesięczne.




Rys. 4.7: Wykres analizy widmowej zmiennej Pracochłonność i zmiennej Pracochłonność przekształconej filtrem 4325 H.

Największe wartości periodogramu uzyskano przy wartości okresu równym 12 (rys 4.7) oraz (tabela 4.1). Na wykresie periodogramu widać wyraźny szczyt. Świadczy to o tym, że sezonowość w przypadku przekształconego szeregu pracochłonności wynosi 12 (jeden rok). W tabeli 4.1 zestawiono wartości częstości, okresu, współczynników przy cos i sin, wartości periodogramu oraz wartość gęstości.

Tabela 4.1: Wyniki analizy widmowej zmiennej Pracochłonność (dane po agregacji - miesięczne).

Analiza widmowa: Pracochłonność: 4253H(x)					
Liczba obserwacji; 122 okresy miesięczne					
Największe wartości periodogramu					
Częstość	Okres	Współczynniki przy cos	Współczynniki przy sin	Periodogram	Gęstość
,081967	12,2000	-36,7158	-69,2648	374885,8	237814,5
,032787	30,5000	-36,2623	42,6873	191366,4	117695,1
,073770	13,5556	-52,1086	-7,6822	169233,4	188249,3
,090164	11,0909	-7,7267	-40,4817	103606,8	160262,2
,024590	40,6667	11,0484	-39,6588	103388,0	97176,8
,057377	17,4286	-35,3675	-19,5995	99735,0	74463,5
,098361	10,1667	-17,8310	-28,3961	68581,4	76175,9
,065574	15,2500	-25,7540	18,9999	62480,2	107303,0
,008197	122,0000	24,5198	14,8064	50047,5	30296,5
,131148	7,6250	-25,0480	9,5164	43795,8	28238,7

Wartości periodogramu zostały obliczone jako suma kwadratów współczynników przy sinusach i cosinusach dla każdej częstotliwości. Wartości periodogramu można interpretować w kategoriach wariancji (sum kwadratów) odpowiadającej danej częstotliwości lub okresowi. Ocena gęstości widmowej obliczono przez wygładzenie wartości periodogramu. Pozwoliło to na zidentyfikowanie ogólnych "obszarów" częstotliwości lub gęstości widmowych, które mają istotny wkład w cykliczne zachowanie szeregu. Należy przy tym zaznaczyć, że wagi wykorzystane do wygładzania zostają wystandaryzowane, tak aby sumowały się do 1.0.



Rys. 4.8: Wykres analizy widmowej wybranych zmiennych: Płatowiec i URE.

Współczynniki przy funkcji cosinus i sinus można interpretować jako współczynniki regresji, to znaczy mówią one do jakiego stopnia odpowiednie funkcje cosinus lub sinus są skorelowane z danymi przy odpowiednich częstotliwościach.

W związku z tym, że dla danych dziennych brak było możliwości określenia okresu, tym bardziej po podzieleniu statku powietrznego na podzespoły nie będzie można określić okresu. Analizę Fouriera przeprowadzono więc przykładowo dla danych miesięcznych dla napraw płatowca oraz URE (rys. 4.8). Umożliwi to dokładniejsze określenie pracochłonności napraw w następnym roku.

Wyraźnie widać zaznaczony okres 12. Można zatem przystąpić do dekompozycji sezonowej szeregu, a następnie do przeprowadzenia prognozowania. Prognozę wykonano również w przypadku pracochłonności napraw płatowca w celu porównania dokładności uzyskanych wyników z naprawami całego statku powietrznego.

4.2.2. Dekompozycja sezonowa badanych szeregów


Przed przystąpieniem do dekompozycji sezonowej badany szereg (okresy miesięczne z 10 lat) podzielono na okresy: 7, 8, 9, 10 lat. Jak wspomniano wcześniej „pozostawione” dane z ostatnich 12 miesięcy umożliwią porównanie z prognozą i ocenę jej trafności.



Rys. 4.9: Wykres zmiennej Pracochłonność oraz jej przekształcenia przy pomocy filtra.


Na rysunku 4.9 przedstawiono zmienną Pracochłonność oraz jej przekształcenie przy pomocy filtra 4253H z danych z 9 lat.

Dekompozycję sezonową wykonano w pakiecie STATISTICA PL w przypadku pracochłonności napraw wszystkich podzespołów statków powietrznych. Na początku przeprowadzono dekompozycję sezonową w przypadku modelu sezonowego addytywnego. Wyniki przedstawiono na rys. 4.10 – 4.11.




Rys. 4.10: Wyniki dekompozycji sezonowej w przypadku modelu addytywnego.

Dekompozycja polega na wygładzeniu średnią ruchomą, a następnie na wyznaczeniu wskaźników sezonowości.



Rys. 4.11: Wykres wskaźnika sezonowości w przypadku modelu addytywnego.


W przypadku addytywnym szereg powinien przejawiać równomierne wahania sezonowe, bez względu na ogólny poziom szeregu, natomiast w przypadku multiplikatywnym, wielkość wahań sezonowych powinna zmieniać się w zależności od ogólnego poziomu zjawiska. Przeprowadzono również dekompozycję dla modelu multiplikatywnego.



Rys. 4.12: Wyniki dekompozycji sezonowej w przypadku modelu multiplikatywnego.

Przedstawiona na wykresach średnia ruchoma posiada długość równą długości okresowi wahań. W szeregu złożonym z wartości średniej ruchomej wahań sezonowe oraz zmienność wynikająca z wahań o okresach krótszych jest wyeliminowana. Zatem różnice w modelach addytywnych lub stosunki w modelach multiplikatywnych szeregu empirycznego i wygładzonego pozwalają wyodrębnić składnik sezonowy plus składnik nieregularny.


Wskaźniki sezonowe obliczono jako średnią, dla modeli addytywnych lub średnią medialną, dla modeli multiplikatywnych dla każdego punktu w sezonie. Średnia medialna zbioru wartości jest to średnia po wykluczeniu najmniejszej i największej wartości. Wynikowe wartości reprezentują przeciętny składnik sezonowy szeregu. Przeprowadzona dekompozycja szeregu wskazuje na to, że pracochłonność usuwania awarii osiąga najmniejsze wartości w okresach grudzień – marzec. Przyczyną jest zmniejszenie intensywności wykonywania lotów w okresach zimowych. Jest to spowodowane oblodzeniem, opadami śniegu, czyli pogorszeniem warunków atmosferycznych uniemożliwiających bezpieczne wykonywanie lotów. Najwięcej czasu na usuwanie awarii poświęcono w okresach letnich, które charakteryzują się zdecydowanie lepszymi warunkami atmosferycznymi.




Rys. 4.13: Wykres wskaźnika sezonowości w przypadku modelu multiplikatywnego.

Wykonana dekompozycja sezonowa wykazała występowanie sezonowości. Ponadto, w przypadku zmiennej Pracochłonność zauważa się nieznaczny wzrost czasochłonności napraw w latach późniejszych. Może być to związane ze starzeniem się statków powietrznych. Producent ustala reśurs statków powietrznych w latach od 25 do 30 lat w zależności od rodzaju (SP). W związku z tym, że w 1990 roku badane (SP) miały 10 lat, a w 2000 roku – 20 lat, należy przypuszczać, że w okresie najbliższych 5 lat ilość awarii będzie się nieznacznie zwiększać. Natomiast po osiągnięciu granicy reśursu eksploatacja (SP) może okazać się nieopłacalna i niebezpieczna ze względu na bezpieczeńśtwo osób eksploatujących sprzęt. Zapewne wystąpi większe nasilenie niesprawności. Powstaje w tym momencie pytanie: Czy nadal eksploatować badane (SP)? Odpowiedź można uzyskać po przeprowadzeniu analiz związanych z „opłacalnością” ze względu ekonomicznego oraz przeprowadzeniem odpowiednich badań. Ocena efektywności eksploatacji ze względu na koszty przedstawiono w pracy [Tom1999/1].

Dla porównania z wynikami dotyczącymi awarii wszystkich (SP) przeprowadzono dekompozycję sezonową pracochłonności napraw podzespołów płatowca. Wyniki przedstawiono na rys. 4.14.




Rys. 4.14: Wyniki dekompozycji sezonowej w przypadku modelu addytywnego oraz zmiennej Płatowiec.




Rys. 4.15: Wykres wskaźnika sezonowości w przypadku modelu addytywnego oraz zmiennej Płatowiec.

W przypadku rozpatrywanej zmiennej Płatowiec, zauważa się również zmniejszenie pracochłonności napraw w okresie zimowym. Ponadto w miesiącu kwietniu można zaobserwować nieznaczny spadek pracochłonności. Jest to prawdopodobnie związane z wiosennym okresem świątecznym. Ponadto zmienne warunki atmosferyczne w okresie wiosennym mają wpływ na częstotliwość wykonywania lotów.



Rys. 4.16: Wyniki dekompozycji sezonowej w przypadku modelu multiplikatywnego.




Rys. 4.17: Wykres wskaźnika sezonowości w przypadku modelu multiplikatywnego oraz zmiennej Płatowiec.

Po wykonaniu dekompozycji sezonowej można przystąpić do prognozowania. W literaturze problemu [Cie2001], zaleca się sprawdzenie innych modeli, które mogą w lepszy sposób opisać szereg prognozowany pomimo określenia trendu lub rodzaju modelu. Na wstępie przy pomocy programu STATISTICA poszukiwano zgrubnie optymalne wartości parametrów: α , δ , ϕ oraz γ w zależności od rodzaju modelu. Następnie wprowadzano uzyskane wartości parametrów do programu i automatycznie poszukiwano najlepszych parametrów.

Wyniki prognozowania metodą wyrównywania wykładniczego z danych z 9 lat (nie przekształconych) na następne 12 miesięcy zestawiono w tabeli 4.2. Wyniki prognoz porównano z danymi rzeczywistymi z 2000 roku, a następnie obliczono błędy według wzorów przedstawionych w rozdziale 3.8.

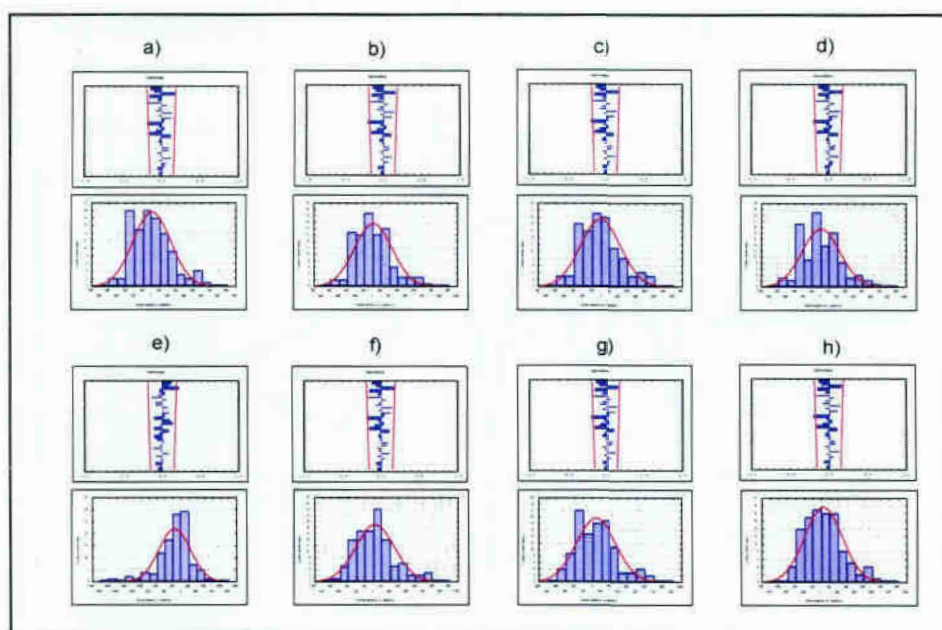
Tabela 4.2: Wyniki wyrównywania wykładniczego zmiennej Pracochłonność.

Model									Wykresy reszt na rys. 4.19
Trend	Składnik sezon	SSE	MSE	MAPE	U_1	U_2	U_3	I^2	
Brak	Addytywny	3654894	304575	36,51%	8,3%	3,6%	88,0%	1,0945	a)
	Multiplikatywny	3654894	304575	35,33%	8,3%	3,4%	88,2%	1,0945	b)
Liniowy	Addytywny	3771959	314329	36,73%	8,3%	3,5%	88,1%	1,1295	c)
	Multiplikatywny	3547615	295635	35,30%	8,3%	3,5%	88,2%	1,0624	d)
Wykładniczy	Brak	1469285	122440	24,52%	8,3%	28,3%	63,4%	0,4400	e)
	Addytywny	1558730	129894	32,74%	8,3%	8,5%	83,2%	0,4668	f)
Gasnący	Addytywny	5536938	461411	39,59%	8,3%	2,4%	89,2%	1,6425	g)
	Multiplikatywny	4541051	378420	36,14%	8,3%	3,1%	88,6%	1,3666	h)



Rys. 4.18: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, bez przekształcenia danych.

Przedstawione wykresy (rys 4.18) oraz wyniki w tabeli 4.2 wskazują na osiągnięcie błędu prognozy MAPE rzędu 24-35%. Wykresy autokorelacji reszt modeli (rys. 4.19) sygnalizują brak autokorelacji określonych rzędów. Oznacza to, że uzyskane modele można zaakceptować. Wzrokową ocenę autokorelacji przeprowadzono na podstawie wykresów słupkowych. Wysokość kolejnych słupków odpowiada wartości autokorelacji pomiędzy elementami szeregu oddalonymi od siebie o coraz większą liczbę okresów. W przypadku pojawienia się autokorelacji określonego rzędu należałoby dokonać ponownej analizy modelu.




Rys. 4.19: Wykresy autokorelacji i histogramy reszt w przypadku modeli wyrównywania wykładniczego zmiennej Pracochłonność oraz danych przedstawionych w tabeli 4.2.

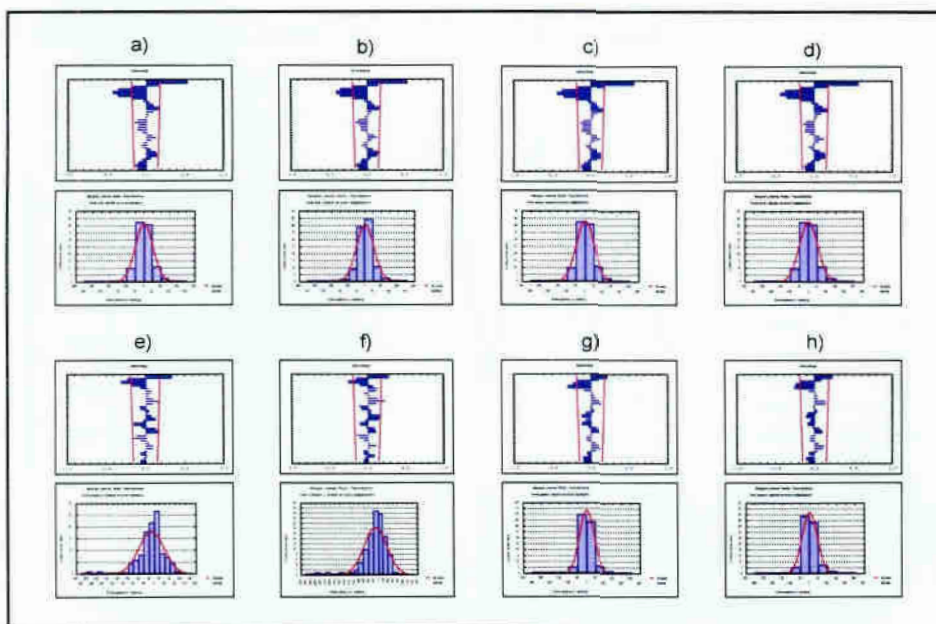
Wyniki wyrównywania wykładniczego z danych z 9 lat (przekształconych filtrem 4253H) na następne 12 miesięcy przedstawiono w tabeli 4.3. Wyniki prognoz porównano z danymi rzeczywistymi z 2000 roku (dla użytkownika ważne są dane rzeczywiste, a nie szereg wygładzony), a następnie obliczono błędy.

Tabela 4.3: Wyniki wyrównywania wykładniczego przy danych przefiltrowanych.

Model		SSE	MSE	MAPE	U_1	U_2	U_3	I^2	Wykresy reszt na rys. 4.21
Brak	Składnik sezon								
	Trend								
Brak	Addytywny	328291	27358	27,42%	8,3%	87,9%	3,8%	0,0983	a)
	Multiplikat.	246484	20540	27,80%	8,3%	95,9%	-4,2%	0,0738	b)
Liniowy	Addytywny	228658	19055	28,15%	8,3%	123,4%	-31,7%	0,0685	c)
	Multiplikat.	159157	13263	28,44%	8,3%	142,5%	-50,8%	0,0477	d)
Wykładniczy	Addytywny	1228600	102383	45,34%	8,3%	9,0%	82,7%	0,3679	e)
	Multiplikat.	3594012	299501	54,34%	8,3%	0,5%	91,2%	1,0763	f)
Gasnący	Addytywny	233167	19431	28,19%	8,3%	123,3%	-31,7%	0,0698	g)
	Multiplikat.	140910	11742	28,47%	8,3%	163,9%	-72,2%	0,0422	h)



Rys. 4.20: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po przekształceniu danych filtrem 4253H.




Rys. 4.21: Wykresy autokorelacji i histogramy reszt różnych modeli zmiennej Pracochłonność, po przekształceniu danych filtrem 4253H (tabela 4.3).

Dane rzeczywiste dotyczące pracochłonności przekształcono również przy pomocy prostego wyrównywania wykładniczego począwszy od $\alpha = (0,1; 0,2; 0,3; \dots; 0,9)$. Przeanalizowano 12 modeli dla każdego α uzyskując 108 modeli. Modele najlepiej opisujące prognozę (uzyskano najmniejsze błędy) przedstawione zostały w tabeli 4.4.

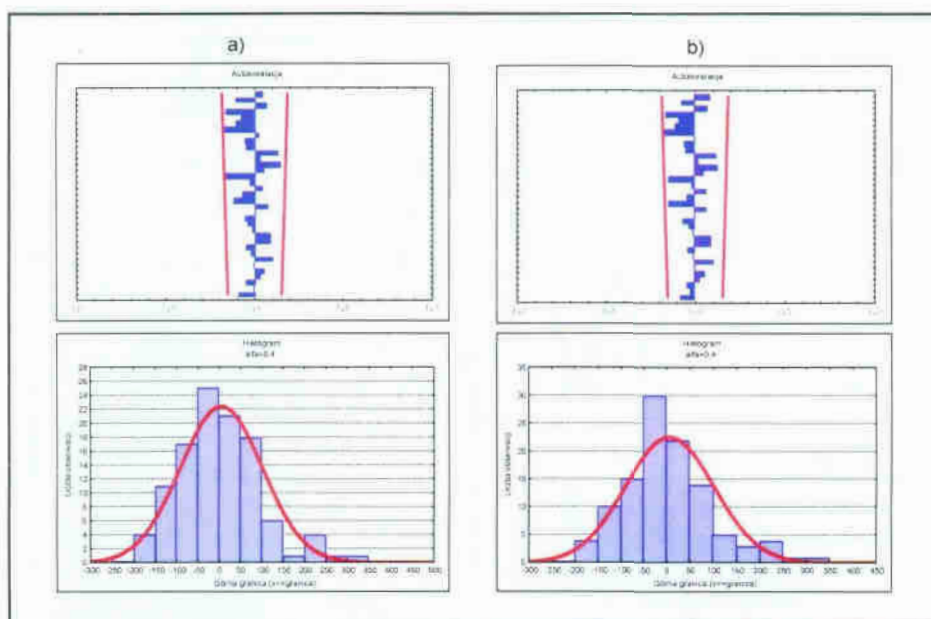
Tabela 4.4: Wyniki wyrównywania wykładniczego przy danych wygładzonych ($\alpha=0,1 \div 0,9$).

Alfa	Model									Wykresy reszt na rys. 4.23
	Trend	Składnik sezon	SSE	MSE	MAPE	U_1	U_2	U_3	I^2	
0,1		Addytywny	1803955	150330	23,88%	8,3%	23,1%	68,5%	0,5402	
		Multiplikat.	1843632	153636	23,95%	8,3%	22,3%	69,4%	0,5521	
0,2		Addytywny	1277916	106493	24,89%	8,3%	28,8%	62,9%	0,3827	
		Multiplikat.	1406111	117176	24,85%	8,3%	25,5%	66,2%	0,4211	
0,3		Addytywny	1089992	90832	25,51%	8,3%	29,8%	61,9%	0,3264	
		Multiplikat.	1248601	104050	25,48%	8,3%	25,3%	66,4%	0,3739	
0,4	Gasnący	Addytywny	1017030	84752	26,17%	8,3%	28,3%	63,4%	0,3046	a)
		Multiplikat.	1146850	95571	26,40%	8,3%	24,0%	67,7%	0,3434	b)
0,5		Addytywny	1133337	94445	26,62%	8,3%	22,6%	69,1%	0,3394	
		Multiplikat.	1217777	101481	26,92%	8,3%	19,7%	71,9%	0,3647	
0,6		Addytywny	5279073	439923	34,57%	8,3%	4,3%	87,4%	1,5809	
		Multiplikat.	5331348	444279	34,15%	8,3%	4,9%	86,7%	1,5965	
0,7		Addytywny	4846414	403868	34,83%	8,3%	4,2%	87,5%	1,4513	
		Multiplikat.	5135343	427945	34,17%	8,3%	4,5%	87,2%	1,5378	
0,8		Addytywny	4668360	389030	35,78%	8,3%	3,8%	87,8%	1,3980	
		Multiplikat.	4652725	387727	34,06%	8,3%	4,2%	87,4%	1,3933	
0,9		Addytywny	4794437	399536	37,18%	8,3%	3,3%	88,4%	1,4357	
		Multiplikat.	4241417	353451	34,72%	8,3%	3,8%	87,8%	1,2701	



Rys. 4.22: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po wygładzeniu $\alpha = 0,1 \div 0,9$.

Najbardziej trafnym modelem okazał się model z trendem gasnącym ze składnikiem sezonowym addytywnym. Błąd prognozy MAPE wynosi 26,17%. Wykres autokorelacji i histogramy reszt modelu z trendem gasnącym i składnikiem addytywnym oraz multiplikatywnym przedstawiono na rys. 4.23.




Rys. 4.23: Wykresy autokorelacji i histogramy reszt w przypadku modeli zmiennej Pracochłonność z trendem gasnącym i składnikiem sezonowym addytywnym i multiplikatywnym oraz szeregiem przekształconym oraz $\alpha=0,4$.

Dane rzeczywiste z 9 lat przekształcono przy pomocy średniej ruchomej N-2 punktowej i obliczono prognozy dla przekształconego szeregu. Błędy prognoz przedstawiono w tabeli 4.5.

Tabela 4.5: Wyniki wyrówn. wykładniczego przy danych przekształconych N-2 pt. średn. ruch.

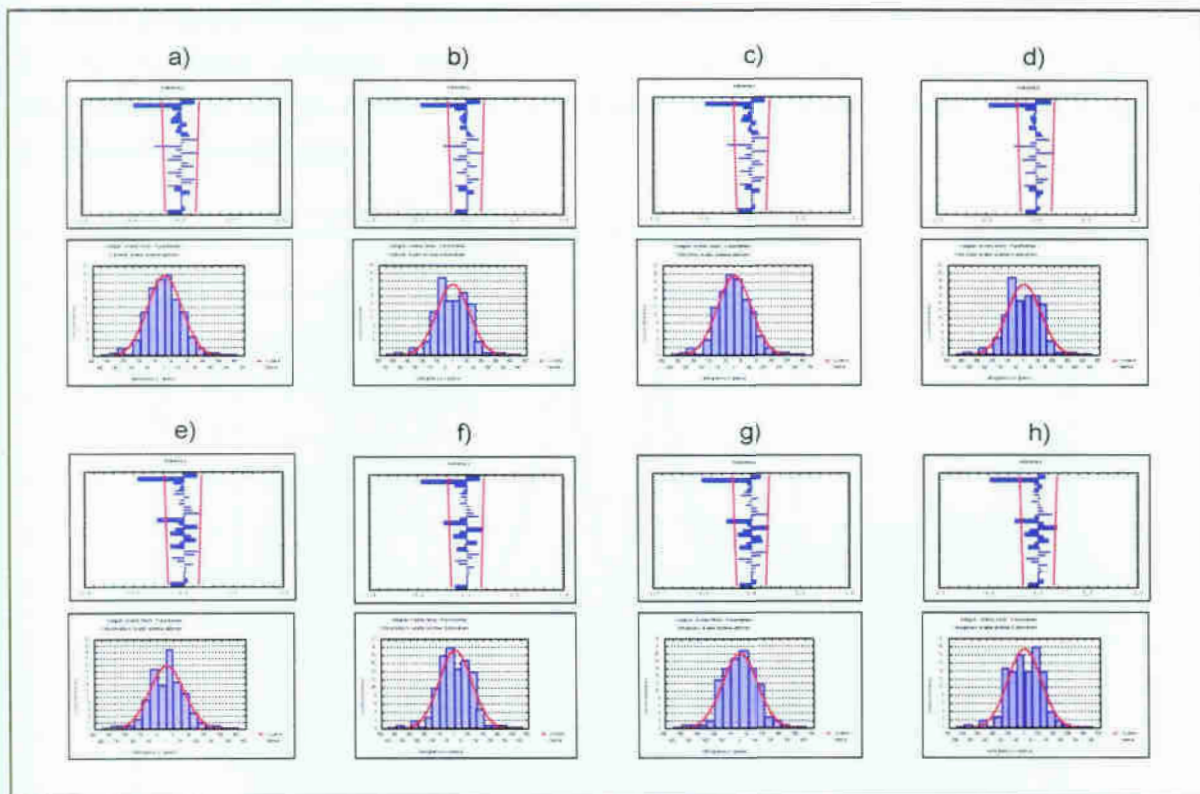
Model									Wykresy reszt na rys. 4.25
Trend	Składnik sezon	SSE	MSE	MAPE	U_1	U_2	U_3	I^2	
Brak	Brak	1159929	96661	25,30%	8,3%	40,3%	51,4%	0,3473	
	Addytywny	477141	39762	29,12%	8,3%	49,3%	42,3%	0,1429	a)
	Multiplikat.	723156	60263	28,83%	8,3%	25,7%	65,9%	0,2166	b)
Liniowy	Brak	731385	60949	27,13%	8,3%	57,7%	34,0%	0,2190	
	Addytywny	406235	33853	29,56%	8,3%	56,9%	34,8%	0,1216	c)
	Multiplikat.	630461	52538	29,30%	8,3%	28,5%	63,1%	0,1888	d)
Wykładniczy	Brak	79897	6658	31,90%	8,3%	385,6%	-1293,9%	0,0239	
	Addytywny	1388133	115678	25,96%	8,3%	19,0%	72,7%	0,4157	e)
	Multiplikat.	1818754	151563	25,82%	8,3%	13,1%	78,6%	0,5446	f)
Gasnący	Brak	1159929	96661	25,30%	8,3%	40,3%	51,4%	0,3473	
	Addytywny	341350	28446	30,06%	8,3%	68,9%	22,8%	0,1022	g)
	Multiplikat.	520856	43405	30,02%	8,3%	34,6%	57,1%	0,1560	h)

Uzyskane błędy prognoz dla danych przekształconych N-2 punktową średnią ruchomą są rzędu 25-32%.



Rys. 4.24: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po przekształceniu danych średnią ruchomą N-2 punktową.

Najbardziej trafnym modelem okazał się model z trendem gasnącym ze składnikiem sezonowym addytywnym.



Rys. 4.25: Wykresy autokorelacji i histogramy reszt w przypadku różnych modeli zmiennej Pracochłonność, po przekształceniu danych N-2 punktową średnią ruchomą (tabela 4.5).


Pomimo błędu 30,06% współczynnik rozbieżności Theila osiąga wartość najmniejszą i wynosi 0,1022. Zdecydowanie należy odrzucić modele bez składnika sezonowego.

Dane rzeczywiste z 9 lat przekształcono przy pomocy mediany ruchomej N=3 punktowej i obliczono prognozy dla przekształconego szeregu. Błędy prognoz przedstawiono w tabeli 4.6.

Tabela 4.6: Wyniki wyrówn. wykładniczego przy danych przekształconych N-3 medianą ruch.

Model								
Trend	Składnik sezon	SSE	MSE	MAPE	U ₁	U ₂	U ₃	I ²
Brak	Brak	1834260	152855	24,16%	8,3%	25,5%	66,2%	0,5493
	Addytywny	223891	18658	31,35%	8,3%	90,1%	1,6%	0,0670
	Multiplikat.	107174	8931	34,95%	8,3%	83,4%	8,3%	0,0321
Liniowy	Brak	1248151	10401	25,43%	8,3%	33,6%	58,1%	0,3738
	Addytywny	140805	11734	32,17%	8,3%	139,3%	-47,7%	0,0422
	Multiplikat.	48548	4046	35,88%	8,3%	164,4%	-74,8%	0,0145
Wykładniczy	Brak	1424512	118709	24,68%	8,3%	32,8%	59,9%	0,4266
	Addytywny	302173	25181	30,71%	8,3%	68,2%	23,5%	0,0905
	Multiplikat.	1123484	93624	32,13%	8,3%	9,7%	82,0%	0,3364
Gasnący	Brak	1912689	159391	24,12%	8,3%	24,4%	67,3%	0,5728
	Addytywny	226699	18892	31,33%	8,3%	89,0%	2,7%	0,0679
	Multiplikat.	99562	8297	35,07%	8,3%	89,2%	2,4%	0,0298

Błędy prognoz MAPE dla pracochłonności napraw (SP) przekształconej N-3 punktową medianą ruchomą osiągają wartość 24-36%. Podobnie jak w przypadku szeregu przekształconego N-2 pt. średn. ruch. i tym razem zdecydowanie należy odrzucić modele bez składnika sezonowego.



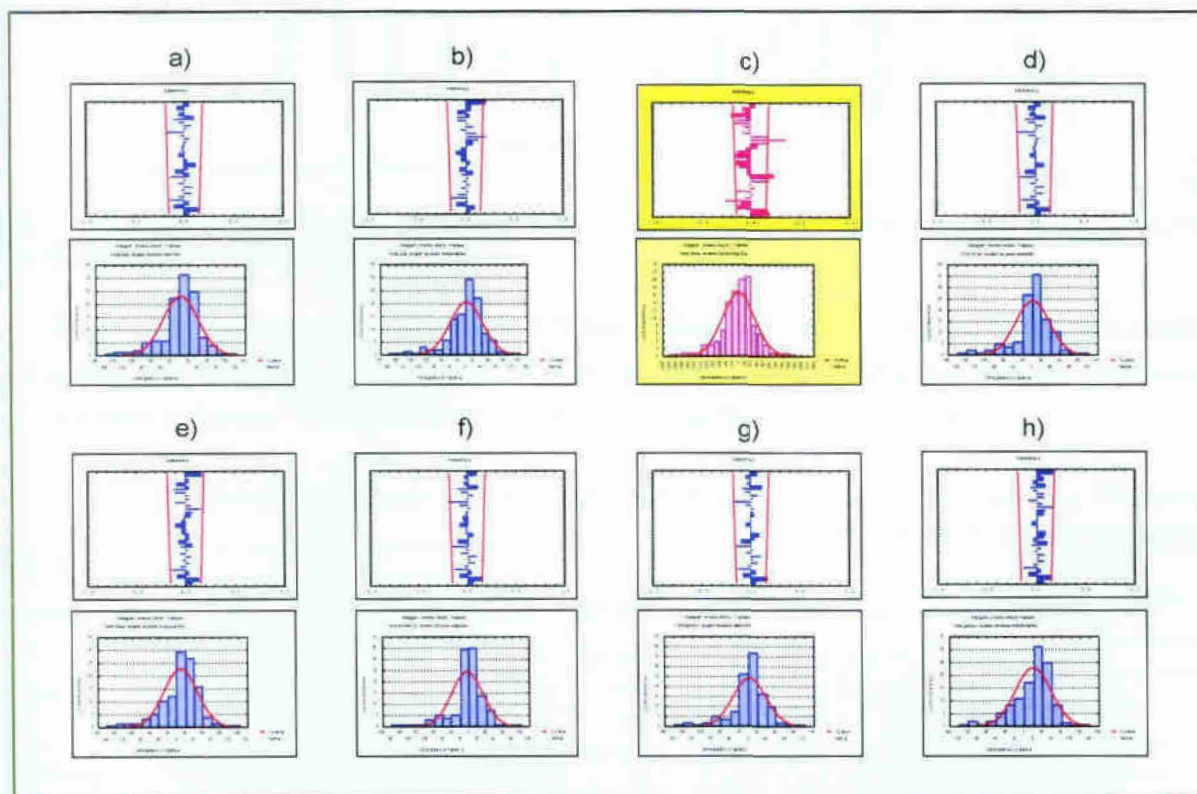
Rys. 4.26: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po przekształceniu danych medianą ruchomą N-3 punktową.

Uzyskane wyniki i prognozy zbyt różnią się od szeregu rzeczywistego. Dlatego też podobną procedurę zastosowano dla danych dotyczących napraw związanych z płatowcem. Uzyskane wyniki i błędy prognoz wyrównywania wykładniczego w przypadku danych rzeczywistych napraw płatowca przedstawiono w tabeli 4.7.

Tabela 4.7: Wyniki wyrównywania wykładniczego w przypadku zmiennej Płatowiec.

Model		SSE	MSE	MAPE	U_1	U_2	U_3	i^2	Wykresy reszt na rys. 4.27
Brak	Brak	367847	30654	34,75%	8,3%	5,7%	86,0%	1,3898	
	Addytywny	7107	592	6,67%	8,3%	2,8%	88,8%	0,0269	a)
	Multiplikat.	914	76	10,26%	8,3%	177,4%	-85,7%	0,0035	b)
Liniowy	Brak	283564	23630	34,37%	8,3%	6,4%	85,2%	1,0714	c)
	Addytywny	5995	500	7,79%	8,3%	3,7%	87,9%	1,0714	d)
	Multiplikat.	2378	198	9,98%	8,3%	76,3%	15,4%	0,0090	e)
Wykładniczy	Addytywny	24541	2045	9,71%	8,3%	0,73%	90,9%	0,0927	f)
Gasnący	Brak	412003	34334	35,24%	8,3%	5,1%	86,6%	1,5567	
	Addytywny	1206	101	6,58%	8,3%	17,8%	73,9%	0,0046	g)
	Multiplikat.	129770	10814	23,05%	8,3%	0,0%	91,7%	0,4903	h)


Najbardziej trafny okazał się model szeregu z trendem gasnącym i składnikiem sezonowym addytywnym.



Rys. 4.27: Wykres autokorelacji histogramy reszt zmiennej Płatowiec w przypadku modeli przedstawionych w tabeli 4.7 (oprócz modeli: brak trendu, brak składnika sezonowego i trend gasnący, brak składnika sezonowego).

Średni bezwzględny błąd procentowy MAPE wyniósł 6,58%, natomiast współczynnik rozbieżności Theila 0,0046. Świadczy to o dobrym dopasowaniu do danych rzeczywistych. Ponadto na rys. 4.27 brak autokorelacji reszt modelu, świadczy o jego poprawności. Zdecydowanie należy odrzucić modele bez składnika sezonowego. Świadczą o tym wyniki przedstawione w tabeli 4.7.

Model z trendem liniowym i brakiem składnika sezonowego przykładowo przedstawiono na rys. 4.27 (tło wykresu - żółte). Zauważalna jest autokorelacja w szeregu reszt.




Rys. 4.28: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego bez przekształcenia danych.

Dane dotyczące napraw płatowca z 9 lat przekształcono filtrem 4253H i dokonano prognozy na następne 12 miesięcy. Wyniki prognoz pracochłonności napraw płatowca porównano z danymi rzeczywistymi z 2000 roku i zestawiono w tabeli 4.8.

Tabela 4.8: Wyniki wyrównywania wykładniczego w przypadku zmiennej Płatowiec przy danych przefiltrowanych.

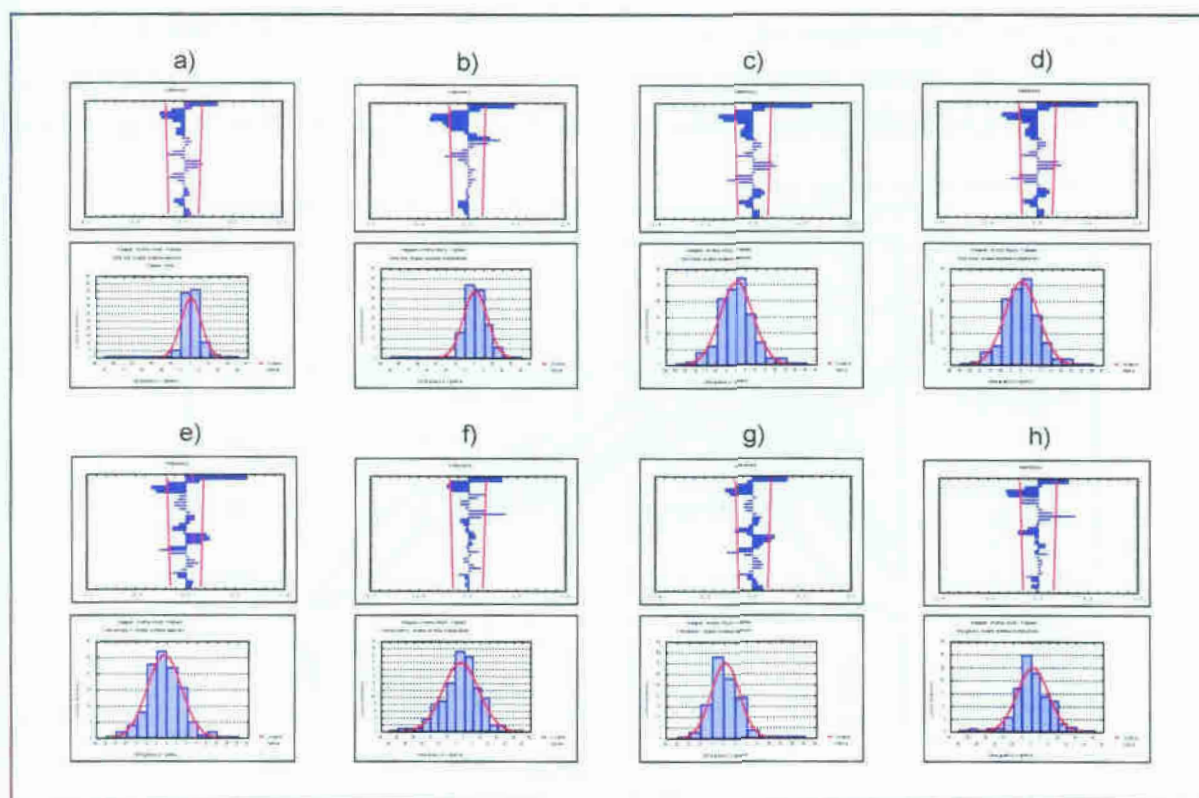
Model									Wykresy reszt na rys. 4.30
Trend	Składnik sezon	SSE	MSE	MAPE	U_1	U_2	U_3	I^2	
Brak	Brak	422581	35215	35,35%	8,3%	5,0%	86,7%	1,5966	
	Addytywny	11713	976	10,30%	8,3%	11,7%	80,0%	0,0443	a)
	Multiplikat.	10177	848	9,66%	8,3%	0,1%	91,6%	0,0385	b)
Liniowy	Addytywny	2468	206	10,34%	8,3%	58,0%	33,7%	0,0093	c)
	Multiplikat.	9529	794	10,30%	8,3%	0,9%	90,8%	0,0360	d)
Wykładniczy	Brak	1687059	140588	73,17%	8,3%	0,4%	91,3%	6,3741	
	Addytywny	11305	942	15,16%	8,3%	12,1%	79,6%	0,0427	e)
	Multiplikat.	102698	8558	20,74%	8,3%	0,5%	91,2%	0,3880	f)
Gasnący	Addytywny	15515	1293	10,57%	8,3%	8,9%	82,7%	0,0586	g)
	Multiplikat.	8547	712	9,46%	8,3%	0,1%	91,6%	0,0323	h)

Zdecydowanie należy odrzucić modele bez składnika sezonowego (błędy MAPE od 35% do 73%). W tym przypadku uzyskane błędy prognoz wynoszą 10-21%. Współczynnik rozbieżności Theila wynosi od 0,0093-0,0586. W przefiltrowanym szeregu wyróżnia się składnik sezonowy addytywny. Według wyników z tabeli zaakceptować można byłoby dwa modele (zaznaczone w tabeli). O ile błędy prognoz MAPE są porównywalne $\approx 10\%$, model z trendem liniowym ma mniejszą wartość U_3 . Świadczy to o mniejszej niezgodności między kierunkiem zmian wartości rzeczywistych i wartości uzyskanych podczas prognoz.



Rys. 4.29: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego przy danych przekształconych filtrem.

Pomimo zbieżności prognoz z danymi rzeczywistymi najbardziej niepokojące wydają się wykresy autokorelacji i histogramy reszt modeli (rys. 4.30) dyskwalifikujące wybrane modele.




Rys. 4.30: Wykresy autokorelacji i histogramy reszt modeli zmiennej Platowiec, przefiltrowanych za pomocą filtra 4253H (tabela 4.8).

W tabeli 4.9 przedstawiono wyniki wyrównywania wykładniczego z danych z 9 lat (przekształconych średnią ruchomą $N=2$ punktową). Podobnie jak dla poprzednich modeli, wyniki prognoz pracochłonności napraw płatowca porównano z danymi rzeczywistymi z 2000 roku.

Tabela 4.9: Wyniki wyrówn. wykładn. zmiennej Platowiec przy danych przekształc. $N=2$ pt. średn. ruch.

Model								
Trend	Składnik sezon	SSE	MSE	MAPE	U_1	U_2	U_3	I^2
Brak	Brak	412164	34347	35,24%	8,3%	5,1%	86,6%	1,5573
	Addytywny	10755	896	15,50%	8,3%	8,2%	83,5%	0,0406
	Multiplikat.	5942	495	16,30%	8,3%	2,3%	89,4%	0,0860
Liniowy	Brak	339835	28320	35,02%	8,3%	5,4%	86,2%	1,2840
	Addytywny	2571	214	16,47%	8,3%	27,8%	63,8%	0,0097
	Multiplikat.	42881	3573	21,97%	8,3%	2,9%	88,8%	0,1620
Wykładniczy	Brak	505575	42131	37,00%	8,3%	3,6%	88,1%	1,9102
	Addytywny	4470	372	20,30%	8,3%	7,8%	83,8%	0,0169
	Multiplikat.	129623	10802	30,45%	8,3%	2,5%	89,2%	0,4898
Gasnący	Brak	681613	56801	42,31%	8,3%	2,9%	88,8%	2,5753
	Addytywny	24306	2026	16,35%	8,3%	3,9%	87,8%	0,0918
	Multiplikat.	40978	3415	20,95%	8,3%	2,6%	89,1%	0,1548

Zdecydowanie należy odrzucić modele bez składnika sezonowego i ze składnikiem sezonowym multiplikatywnym. Wartości błędów prognoz MAPE zawierają się w przedziale od 15,50% do 21,97%. Współczynnik rozbieżności Theila od 0,01 do 0,09.



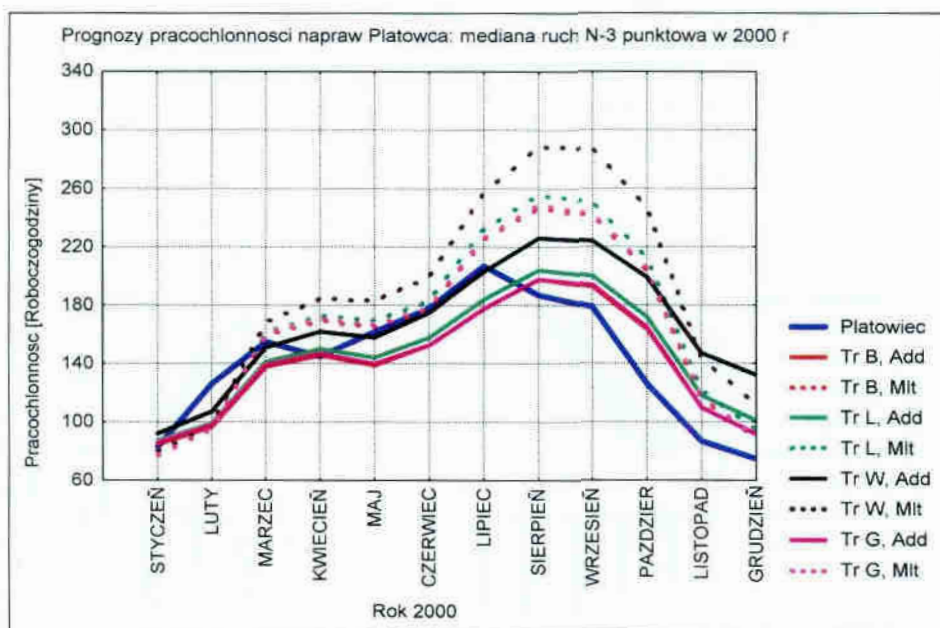
Rys. 4.31: Wykresy prognoz dla zmiennej Platowiec w 2000 r w przypadku modeli wyrównywania wykładniczego, przy danych przekształconych średnią ruchomą N-2 punktową.

Dane rzeczywiste pracochłonności napraw płatowca z 9 lat przekształcono przy pomocy mediany ruchomej N=3 punktowej i obliczono prognozy dla przekształconego szeregu. Błędy prognoz przedstawiono w tabeli 4.10.

Tabela 4.10: Wyniki wyrówn. wykładniczego zmiennej Platowiec danych przekształc. N-3 pt. med. ruch.

Model								
Trend	Składnik sezon	SSE	MSE	MAPE	U ₁	U ₂	U ₃	I ²
Brak	Brak	396900	33075	35,07%	8,3%	5,3%	86,4%	1,5000
	Addytywny	265	22	14,28%	8,3%	103,1%	-11,4%	0,0010
	Multiplikat.	67481	5623	20,40%	8,3%	4,0%	87,7%	0,2550
Liniowy	Brak	325156	27096	34,85%	8,3%	5,7%	86,0%	1,2285
	Addytywny	2466	206	16,66%	8,3%	8,0%	83,6%	0,0093
	Multiplikat.	100187	8349	23,57%	8,3%	3,6%	88,1%	0,3785
Wykładniczy	Brak	396900	33075	35,07%	8,3%	5,3%	86,4%	1,5000
	Addytywny	70836	5903	24,65%	8,3%	0,1%	91,6%	0,2676
	Multiplikat.	289831	24153	36,22%	8,3%	2,9%	88,8%	1,0951
Gasnący	Brak	396900	33075	35,07%	8,3%	5,3%	86,4%	1,5000
	Addytywny	90	8	14,43%	8,3%	303,6%	-212,0%	0,0003
	Multiplikat.	73950	6162	20,86%	8,3%	3,8%	87,9%	0,2794

Uzyskane błędy prognoz wynoszą od 14,28% do 36,22%. Najmniejsze wartości błędów uzyskano dla modelu liniowego i gasnącego ze składnikiem addytywnym.




Rys. 4.32: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego, przy danych przekształconych medianą ruchomą N-3 punktową.

Dane dotyczące pracochłonności napraw płatowca przekształcono również przy pomocy prostego wyrównywania wykładniczego począwszy od $\alpha = (0,1; 0,2; 0,3; \dots; 0,9)$.

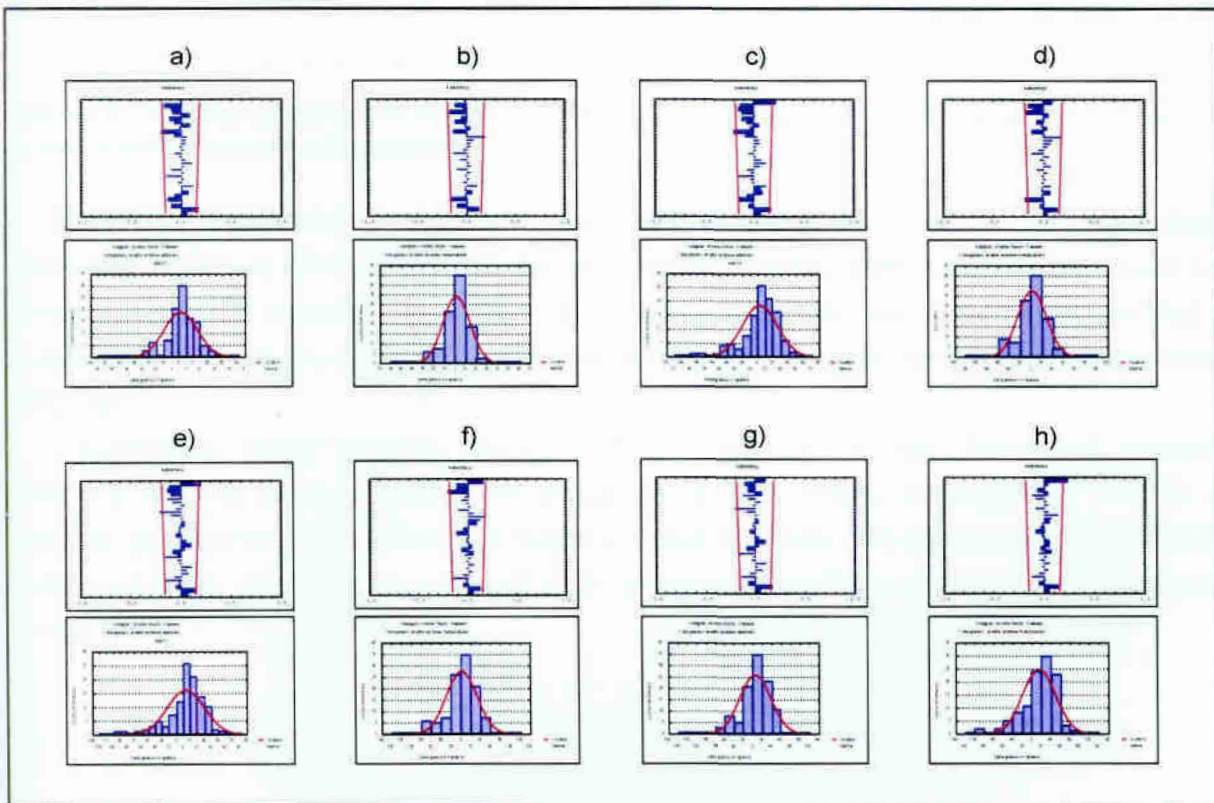
Tabela 4.11: Wyniki wyrówn. wykładni. w przypadku zmiennej Płatowiec oraz danych wygładzonych ($\alpha=0,1 \div 0,9$).

Alfa	Model	Składnik sezon	SSE	MSE	MAPE	U_1	U_2	U_3	I^2	Wykresy reszt na rys. 4.34
0,1	Gasnacy	Addytywny	8170	681	28,57%	8,3%	178,1%	-86,4%	0,0309	
		Multiplikat.	3783	315	27,99%	8,3%	322,4%	-230,7%	0,0143	
0,2		Addytywny	5399	450	26,15%	8,3%	172,9%	-81,3%	0,0204	
		Multiplikat.	400	33	24,79%	8,3%	1559,7%	-1467%	0,0015	
0,3		Addytywny	3728	311	22,34%	8,3%	152,7%	-61,1%	0,0141	a)
		Multiplikat.	1538	128	20,27%	8,3%	143,1%	-51,4%	0,0058	b)
0,4		Addytywny	3107	259	17,97%	8,3%	109,9%	-18,2%	0,0117	
		Multiplikat.	9612	801	16,92%	8,3%	3,4%	88,3%	0,0363	
0,5		Addytywny	3071	256	13,80%	8,3%	67,2%	24,5%	0,0116	
		Multiplikat.	25010	2084	14,18%	8,3%	0,9%	91,5%	0,0945	
0,6		Addytywny	3945	328,8	10,24%	8,3%	32,3%	59,4%	0,0149	c)
		Multiplikat.	13692	1141	11,85%	8,3%	1,8%	89,9%	0,0517	d)
0,7	Addytywny	5501	458	7,80%	8,3%	14,6%	77,1%	0,0208	e)	
	Multiplikat.	34203	2850	12,32%	8,3%	3,8%	87,9%	0,1292	f)	
0,8	Addytywny	6736	561	6,40%	8,3%	7,6%	84,1%	0,0255	g)	
	Multiplikat.	17286	1441	10,88%	8,3%	1,1%	90,6%	0,0653	h)	
0,9	Addytywny	7472	623	6,17%	8,3%	4,4%	87,3%	0,0282		
	Multiplikat.	17658	1471	11,74%	8,3%	2,1%	89,6%	0,0667		

Przeanalizowano 12 modeli dla każdego α uzyskując 108 modeli. Modele najlepiej opisujące prognozę (uzyskano najmniejsze błędy) przedstawione zostały w tabeli 4.11 i na rys.4.33.




Rys. 4.33: Wykresy prognoz dla zmiennej *Platowiec* w 2000 r w przypadku modeli wyrównywania wykładniczego, po wygładzeniu danych przy $\alpha = 0,1 \div 0,9$.



Rys. 4.34: Wykresy autokorelacji i histogramy reszt w przypadku wybranych modeli przedstawionych w tabeli 4.11.


Przedstawione na rys. 4.33 wyniki jednoznacznie wskazują na to, że zbyt „wygładzone” dane niekorzystnie wpływają na prognozę. Optymalne wartości uzyskano dla modeli ze składnikiem addytywnym o współczynniku $\alpha=0,5\div 0,9$.



Rys. 4.35: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku najlepiej pasujących modeli wyrównywania wykładniczego.

Ponieważ użytkownika interesuje końcowy wynik (prognoza o jak najlepszej trafności), najlepsze modele prognoz pracochłonności napraw płatowca przedstawiono na rysunku poniżej. Z zaprezentowanych wykresów można wywnioskować, że mniejsze błędy prognoz uzyskuje się po podzieleniu statku powietrznego na podzespoły (awarie płatowca, URE itp.).

Najmniejsze błędy prognoz MAPE-6,58% w przypadku pracochłonności napraw płatowca w 2000 roku, uzyskano bez przekształcania zmiennej w przypadku modelu z trendem gasnącym i składnikiem sezonowym addytywnym. Wykorzystując ten model, przeprowadzono prognozy przy danych z 10. lat na następne 2 lata. Wyniki przedstawiono na rys. 4.36.



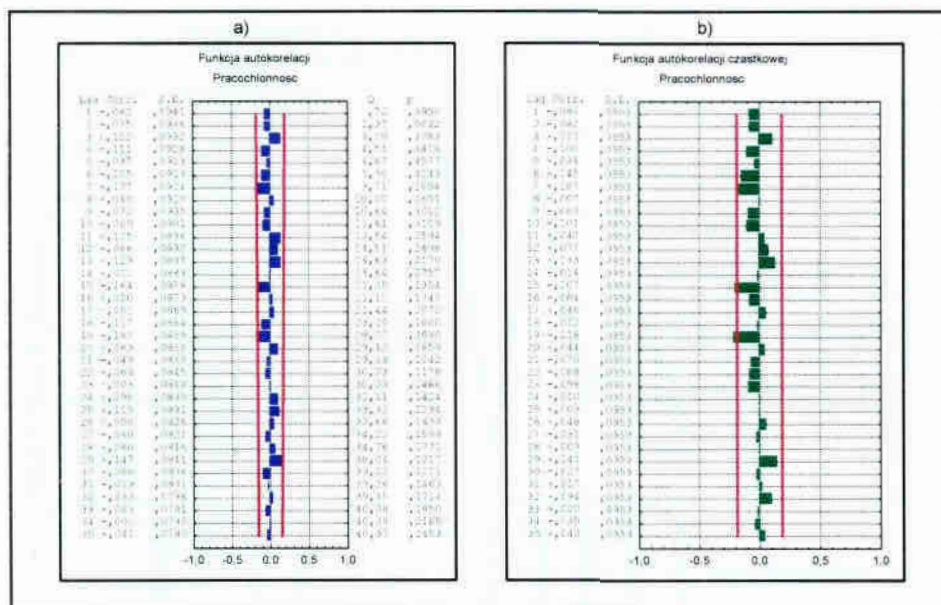
Rys. 4.36: Wykresy prognoz dla zmiennej Płatowiec w latach 2001 – 2002 w przypadku modelu z trendem gasnącym i składnikiem sezonowym addytywnym.

4.2. Wyniki metody ARIMA

Przy budowie modeli ARIMA wykorzystano te informacje, które uzyskano w poprzednim podrozdziale. W pierwszym etapie, przed prognozowaniem, należy przeprowadzić identyfikację podklasy odpowiedniej modeli z ogólnej rodziny modeli ARIMA. W celu określenia czy badany szereg jest stacjonarny (występuje stały poziom zmiennej prognozowanej i wahania przypadkowe) dla napraw wszystkich statków powietrznych sporządzono wykres autokorelacji.

Tabela 4.12: Wartości współczynników ACF w przypadku zmiennej Pracochłonność.

Opóźnienie (w miesiącach)	Współczynnik autokorelacji	Opóźnienie (w miesiącach)	Współczynnik autokorelacji	Opóźnienie (w miesiącach)	Współczynnik autokorelacji
1	-0,080014	13	0,129224	25	0,114809
2	-0,075471	14	0,011109	26	0,049689
3	0,122024	15	-0,184303	27	-0,060083
4	-0,110545	16	0,020112	28	0,060083
5	-0,036943	17	0,050706	29	0,146715
6	-0,105436	18	-0,117313	30	-0,087657
7	-0,176576	19	-0,187107	31	-0,019370
8	0,048618	20	0,088652	32	0,032903
9	-0,072463	21	-0,048683	33	-0,063026
10	-0,088780	22	-0,065605	34	-0,001968
11	0,124579	23	0,002557	35	-0,041388
12	0,087555	24	0,098082	36	-0,040193




Rys. 4.37: Wykres współczynników: a) autokorelacji; b) autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat.

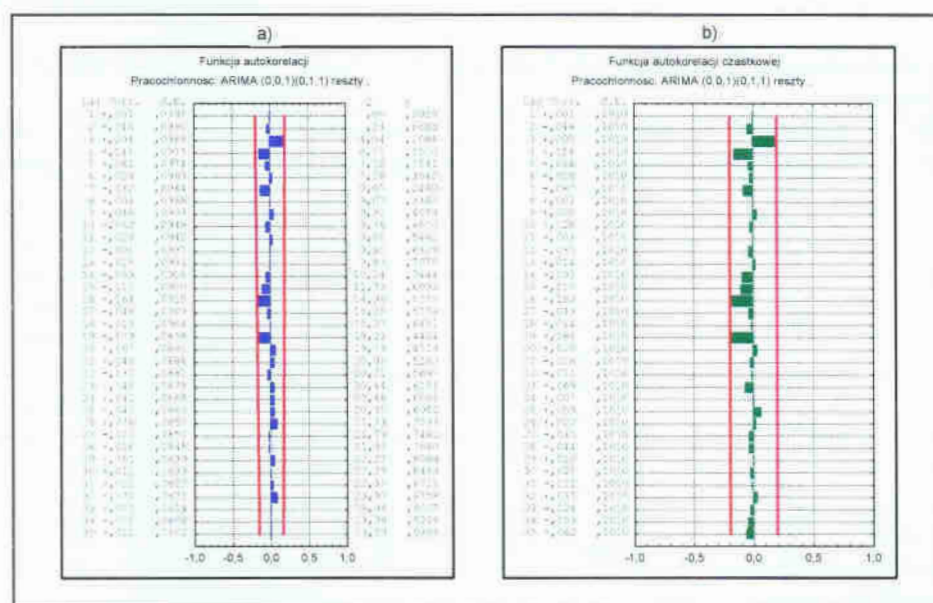
Wyniki przedstawione na rys. 4.37 oraz w tabeli 4.11 świadczą o tym, że szereg jest stacjonarny. Pomimo tego, wcześniejsza analiza szeregu wskazuje na to, że w szeregu występuje okresowość o wartości 12. Dlatego też, podczas poszukiwania modelu ARIMA badany szereg poddano różnicowaniu. W literaturze problemu, niekiedy zaleca się poddać szereg przekształceniu logarytmicznemu [Sta1994]. Ponieważ w szeregu wystąpiły miesiące, w których pracochłonność napraw wynosiła 0rh, nie można było przeprowadzić przekształcenia logarytmicznego. W znalezionym modelu reszty nie powinny „przejawiać” okresowości. Modelem „najlepiej” opisującym badany szereg jest model ARIMA (0,0,1)(0,1,1). Ponadto w modelu (0,0,1)(0,1,1) brak jest autokorelacji reszt (rys. 4.39).

Tabela 4.13: Wyniki prognozy dla zmiennej Pracochłonność przy danych nie przekształconych.

MODEL	SSE	MSE	MAPE	SS	U ₁	U ₂	U ₃	I ²
(0,0,1)(0,1,1)	2462080	205173	27,98%	72,8%	8,3%	6,8%	84,9%	0,7373




Rys. 4.38: Prognoza dla zmiennej Pracochłonność przy danych z 9 lat w przypadku modelu ARIMA $(0,0,1)(0,1,1)$.



Rys. 4.39: Wykres współczynników: a) autokorelacji reszt; b) autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat oraz modelu $(0,0,1)(0,1,1)$.

Na rysunku 4.39 brak jest autokorelacji reszt modelu $(0,0,1)(0,1,1)$. Jednak średni bezwzględny błąd procentowy prognozy osiąga wartość 27,98%, a współczynnik rozbieżności Theila 0,7373.

Podobnie jak w przypadku wyrównywania wykładniczego szereg opisujący pracochłonność napraw statków powietrznych „wygładzono” przy pomocy filtra 4253H (rys. 4.8). Na rysunku 4.40 przedstawiono funkcję autokorelacji szeregu przekształconego filtrem.



Rys. 4.40: Wykres funkcji autokorelacji zmiennej Pracochłonność w przypadku danych z 9 lat przekształconych filtrem 4253H.

Tabela 4.14: Wartości współczynników ACF dla zmiennej Pracochłonność oraz danych przefiltrowanych.

Opóźnienie (w miesiącach)	Współczynnik autokorelacji	Opóźnienie (w miesiącach)	Współczynnik autokorelacji	Opóźnienie (w miesiącach)	Współczynnik autokorelacji
1	0,866478	13	0,106528	25	0,236967
2	0,584236	14	0,006376	26	0,249965
3	0,252073	15	-0,112741	27	0,248967
4	-0,042752	16	-0,231956	28	0,231425
5	-0,245445	17	-0,321280	29	0,187480
6	-0,329993	18	-0,363538	30	0,120772
7	-0,304066	19	-0,357717	31	0,049157
8	-0,206952	20	-0,294679	32	0,001270
9	-0,078573	21	-0,172772	33	0,000204
10	0,048995	22	-0,020665	34	0,040665
11	0,139290	23	0,112279	35	0,104156
12	0,160233	24	0,196619	36	0,167315


Według [Box1983] jeśli funkcja autokorelacji nie ma tendencji do szybkiego zanikania, można to uważać za istnienie niestacjonarności. W tym celu należałoby przeprowadzić d -krotną operację różnicowania. Niezbędny dla osiągnięcia stacjonarności rząd różnicy zostaje osiągnięty, jeśli tylko funkcja autokorelacji szeregu dostatecznie szybko zanika.

Z przedstawionego rysunku 4.40 wynika (w porównaniu z tabelą 3.3), że dla badanego szeregu należałoby zastosować model mieszany ARIMA. Poprzez kolejne powiększanie parametrów p , q , ps , qs , kontrolę istotności parametrów oraz funkcji autokorelacji reszt poszukiwano dopuszczalnych modeli. Jedynym modelem, w którym brak było autokorelacji reszt był model $(1,0,2)(0,1,1)$. Następnie badany szereg poddano przekształceniu logarytmicznemu i przeprowadzono powtórne poszukiwanie modeli.

Wyniki dopuszczalnych modeli wraz z błędami prognozy przedstawiono w tabeli 4.15.

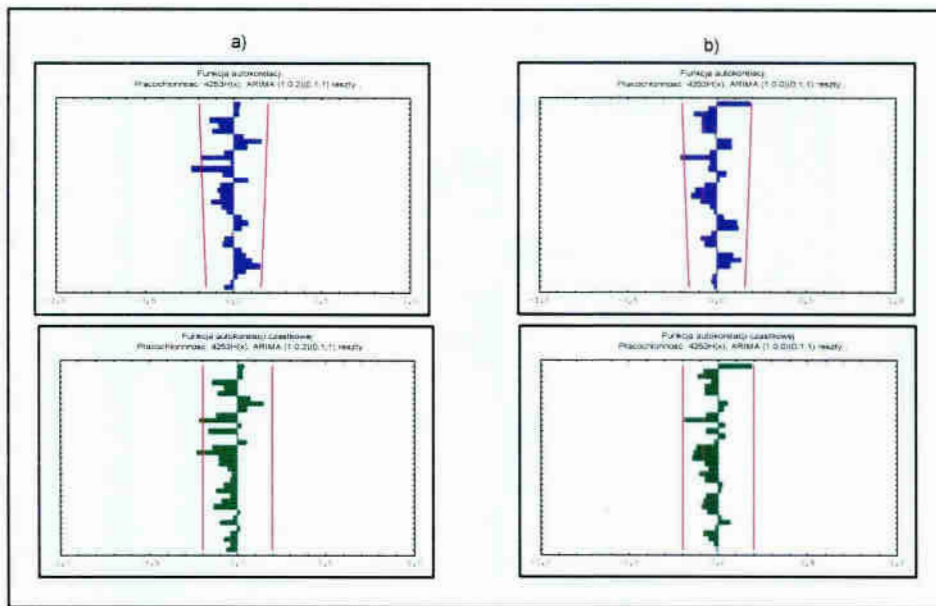
Tabela 4.15: Wyniki prognozy dla zmiennej Pracochłonność oraz danych przefiltrowanych.

MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	i^2
(1,0,2)(0,1,1)	2168980	180748	25,40%	10,8%	8,3%	15,6%	76,3%	0,6495
(1,0,0)(0,1,1)	2300154	191679	25,81%	35,4%	8,3%	14,0%	77,7%	0,6888
(2,0,0)(0,1,0)	1526169	127181	24,72%	35,0%	8,3%	24,0%	67,7%	0,4570
(1,0,1)(0,1,0)	1557169	129764	24,72%	35,0%	8,3%	23,3%	68,3%	0,4663

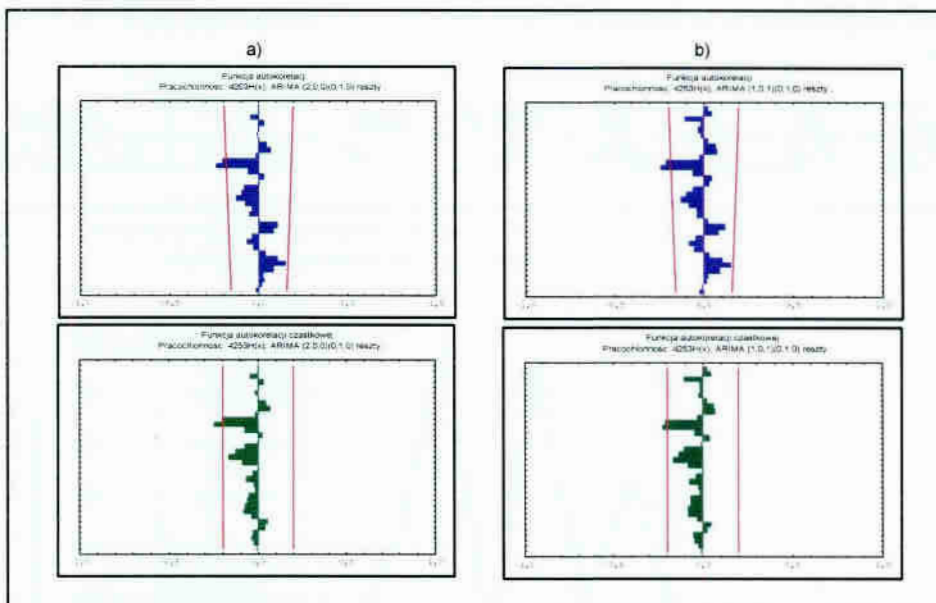


Rys. 4.41: Wykresy prognoz dla zmiennej Pracochłonność w przypadku danych przeksztalconych filtrem 4253H oraz modeli ARIMA.

Po przefiltrowaniu szeregu (po wyrównaniu wartości miesiące z zerową pracochłonnością uzyskały inną wartość) i poddaniu przeksztaleni logarytmicznemu uzyskano 4 modele ARIMA, w których było brak autokorelacji reszt modelu. Błędy prognoz wyniosły od 24,72% do 25,81%. Zbliżone wartości uzyskały dwa modele ARIMA: (2,0,0)(0,1,0) oraz (1,0,1)(0,1,0). Poddanie szeregu filtrowaniu zmniejszyło błąd prognozy o 3% i wartość współczynnika rozbieżności Theila o 0,3. Wykresy współczynników autokorelacji reszt i autokorelacji cząstkowych przedstawiono na rys 4.42 – 4.43.




Rys. 4.42: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłonność przy danych z 9 lat przekształconych filtrem 4253H: a) model $(1,0,2)(0,1,1)$; b) model $(1,0,0)(0,1,1)$.



Rys. 4.43: Wykresy współczynników autokorelacji reszt i współczynników autokorelacji cząstkowej zmiennej Pracochłonność przy danych z 9 lat przekształconych filtrem 4253H: a) model $(2,0,0)(0,1,0)$ b) model $(1,0,1)(0,1,0)$.


Dane rzeczywiste z 9 lat przekształcono przy pomocy średniej ruchomej $N=2$ punktowej i obliczono prognozy dla przekształconego szeregu. Po przekształceniu logarymicznym szeregu kolejno powiększano parametry p , q , ps , qs . Uzyskano model $(0,0,1)(0,1,1)$. Błędy prognozy przedstawiono w tabeli 4.16, natomiast wykres autokorelacji reszt modelu na rys 4.46.



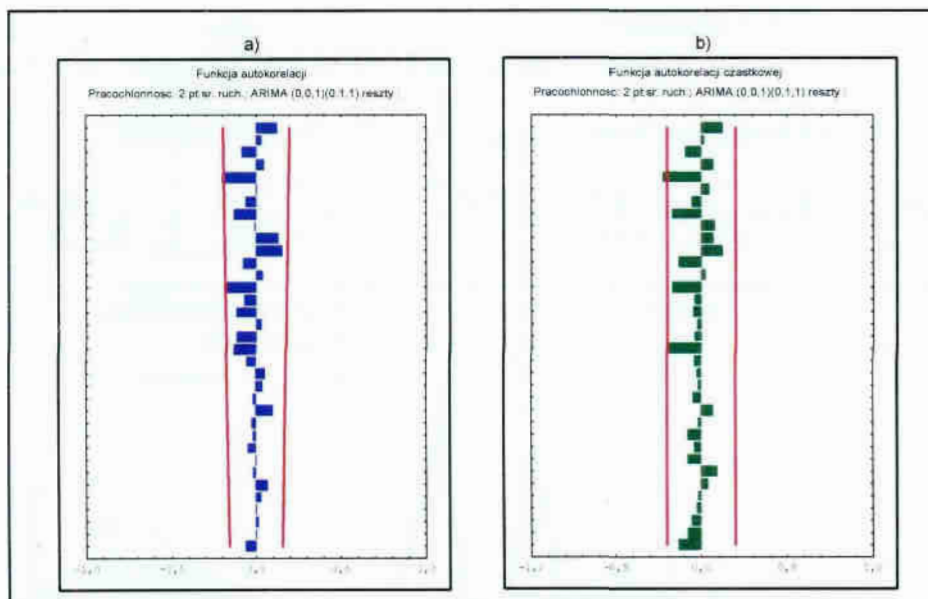
Rys. 4.44: Wykres współczynników autokorelacji zmiennej Pracochłonność w przypadku danych z 9 lat przekształconych N-2 punktową średnią ruchomą.

Tabela 4.16: Wyniki prognozy dla zmiennej Pracochłonność oraz danych przekształc. N-2 pt. średn., ruch.,

MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	i^2
$(0,0,1)(0,1,1)$	3142544	261879	29,42%	44,5%	8,3%	9,2%	82,5%	0,9411




Rys. 4.45: Prognoza dla zmiennej Pracochłonność w 2000 r w przypadku szeregu przekształconego N-2 pt. średn. ruch. oraz modelu ARIMA $(0,0,1)(0,1,1)$.



Rys. 4.46: Wykres współczynników autokorelacji reszt zmiennej Pracochłonność w przypadku danych z 9 lat przekształconych N-2 punktową średnią ruchomą: a) autokorelacja reszt modelu $(0,0,1)(0,1,1)$ b) autokorelacja cząstkowa reszt modelu $(0,0,1)(0,1,1)$.

Uzyskany model po przekształceniu szeregu N-2 pt. średnią ruchomą to $(0,0,1)(0,1,1)$. Podczas prognozowania wymagane było przekształcenie logarytmiczne szeregu.

Dane rzeczywiste z 9 lat przekształcono przy pomocy mediany ruchomej N=3 punktowej i obliczono prognozy dla przekształconego szeregu.

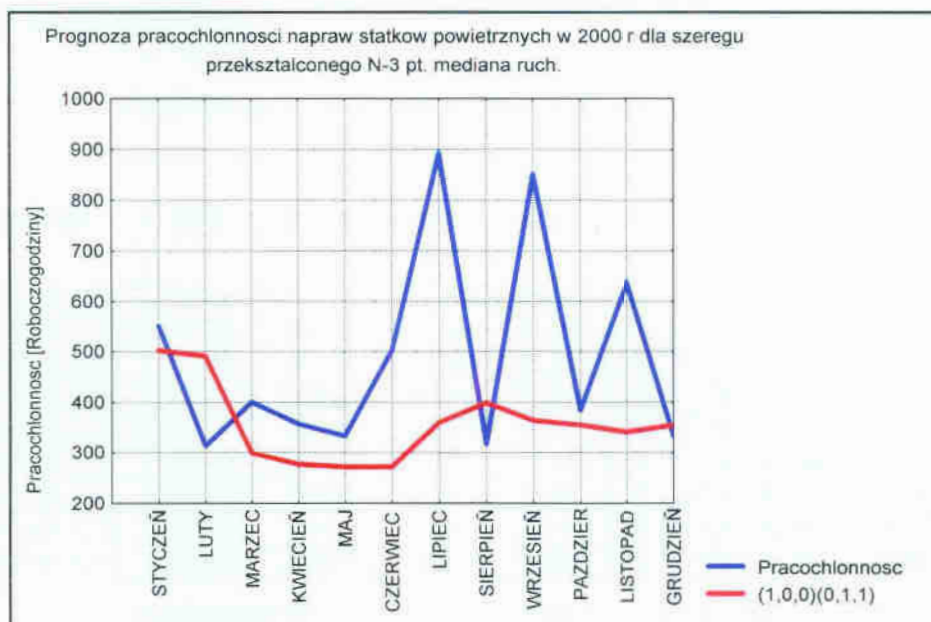


Rys. 4.47: Wykres współczynników autokorelacji zmiennej Pracochłonność przy danych z 9 lat przekształconych medianą ruchomą N-3 punktową.

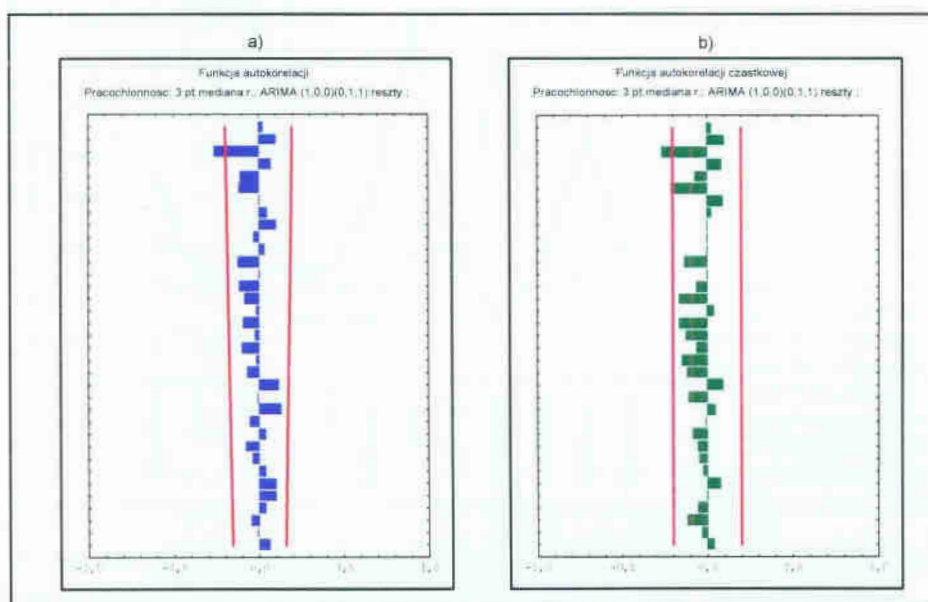
Podczas prognozowania nie było wymagane przekształcenie logarymiczne. Po zróżnicowaniu sezonowym szeregu uzyskano model $(1,0,0)(0,1,1)$.

Tabela 4.17: Wyniki prognozy dla zmiennej Pracochłonność oraz danych przekształconych N-3 pt. med. ruch.

MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	I^2
$(1,0,0)(0,1,1)$	2509734	209145	31,75%	50,8%	8,3%	7,3%	84,4%	0,7516



Rys. 4.48: Prognoza dla zmiennej Pracochłonność w przypadku szeregu przekształconego N-3 pt. medianą ruch. oraz modelu ARIMA $(1,0,0)(0,1,1)$.




Rys. 4.49: Wykres współczynników autokorelacji reszt zmiennej Pracochłonność przy danych z 9 lat przekształconych medianą ruchomą N-3 punktową a) autokorelacja reszt modelu $(1,0,0)(0,1,1)$ b) autokorelacji cząstkowa reszt modelu $(1,0,0)(0,1,1)$.

Uzyskano model $(1,0,0)(0,1,1)$. W tym przypadku nie było konieczne przekształcenie logarytmiczne szeregu przed prognozowaniem. Jednak średni bezwzględny błąd procentowy MAPE osiąga wartość 31,75%.

Szereg dotyczący pracochłonności napraw wygładzono dla $\alpha=0,1 \div 0,9$. Tylko po przekształceniu szeregu dla $\alpha=0,9$ wymagane było przekształcenie logarytmiczne przed prognozowaniem. Następnie poszukiwano dopuszczalnych modeli. Uzyskane wyniki przedstawiono w tabeli 4.18.

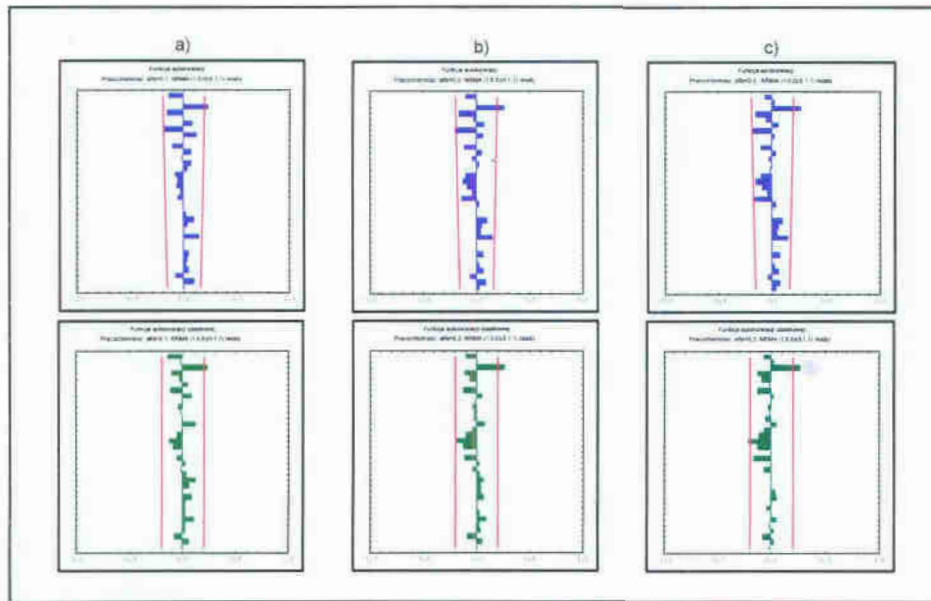
Tabela 4.18: Wyniki prognozy dla zmiennej Pracochłonność oraz danych wygładzonych przy $\alpha=0,1 \div 0,9$.

Alfa	MODEL	SSE	MSE	MAPE	SS	U ₁	U ₂	U ₃	i ²	Wykresy reszt na rys. 4.51-4.53
0,1	(1,0,0)(0,1,1)	2113392	176116	24,21%	30,6%	8,3%	19,7%	72,0%	0,6329	a)
0,2	(1,0,0)(0,1,1)	2217383	184782	24,14%	46,5%	8,3%	17,0%	74,7%	0,6640	b)
0,3	(1,0,0)(0,1,1)	2364712	197059	24,70%	58,3%	8,3%	14,9%	76,8%	0,7081	c)
0,4	(1,0,0)(0,1,1)	2447074	203923	25,75%	67,6%	8,3%	13,4%	78,3%	0,7328	d)
0,5	(1,0,0)(0,1,1)	2482312	206859	26,59%	74,0%	8,3%	12,1%	79,6%	0,7433	e)
0,6	(0,0,0)(0,1,1)	2449495	204125	27,07%	79,0%	8,3%	11,0%	80,7%	0,7335	f)
0,7	(0,0,0)(0,1,1)	2479206	206601	27,43%	79,0%	8,3%	9,8%	81,8%	0,7424	g)
0,8	(0,0,0)(0,1,1)	2510170	209181	27,56%	79,0%	8,3%	8,8%	82,9%	0,7517	h)
0,9	(0,0,0)(0,1,1)	4003653	333638	33,07%	77,8%	8,3%	4,6%	87,0%	1,1989	i)

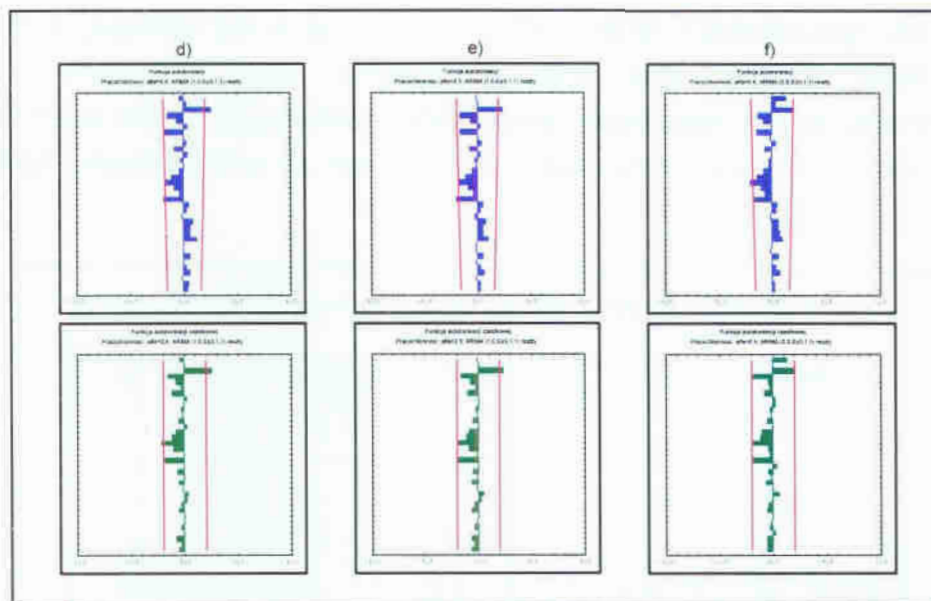


Rys. 4.50: Prognozy dla zmiennej Pracochłonność w przypadku modeli ARIMA oraz szeregu przekształconego wygładzaniem przy $\alpha=0,1 \div 0,9$.

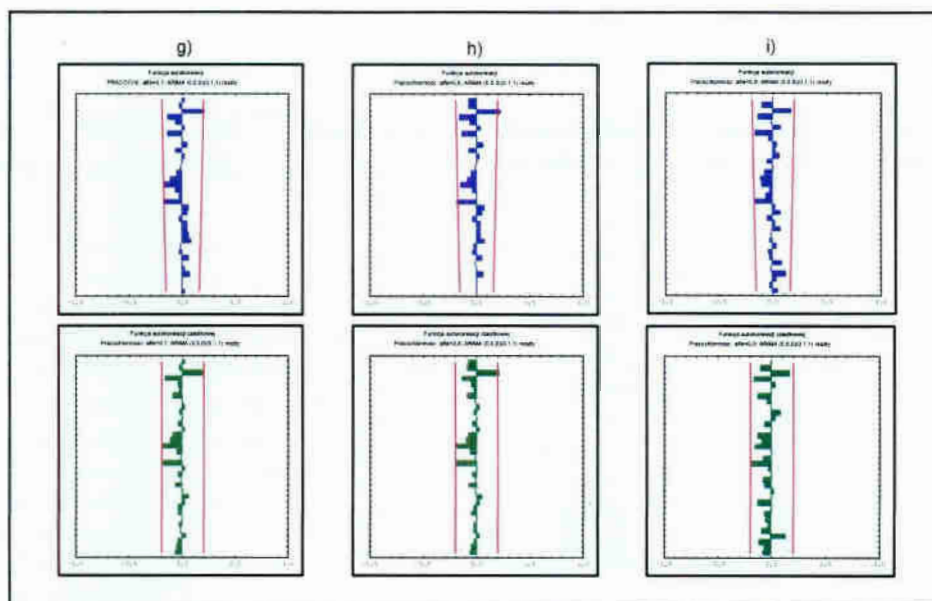
Błędy prognoz MAPE osiągają wartości od 24,2% do 33,1%. Im większa wartość alfa (szereg mniej wygładzony), tym mniejsza wartość błędu. Wraz ze zwiększaniem alfa następuje wzrost rozbieżności Theila. Wykresy współczynników autokorelacji i autokorelacji cząstkowych uzyskanych modeli przedstawiono na rys 4.51 – 4.53.



Rys. 4.51: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłomość w przypadku danych z 9 lat w zależności od alfa z przedziału $0,1 \div 0,3$ (tabela 4.18).

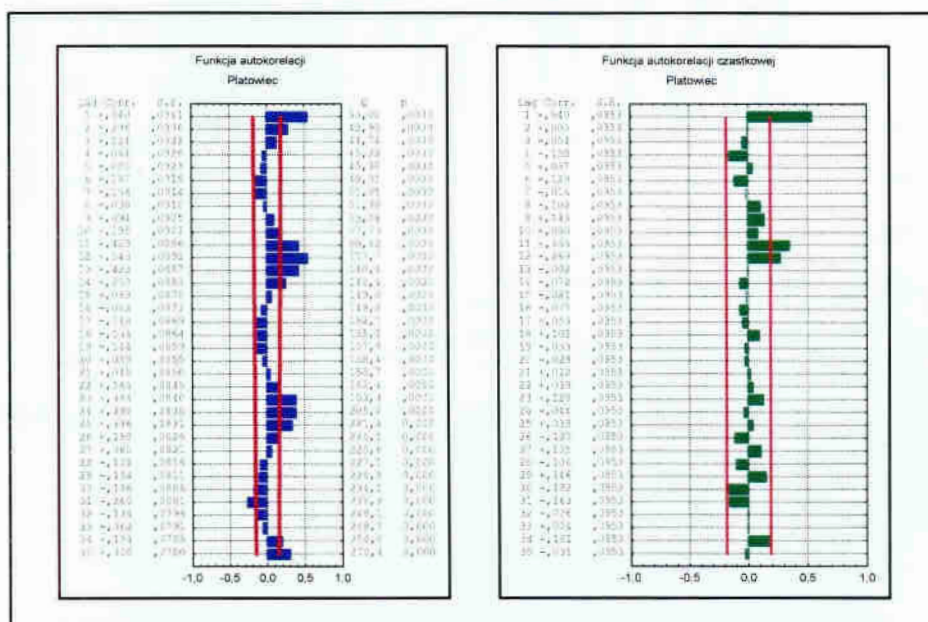


Rys. 4.52: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłomość w przypadku danych z 9 lat w zależności od alfa z przedziału $0,4 \div 0,6$ (tabela 4.18).



Rys. 4.53: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat w zależności od alfa z przedziału 0,7 ÷ 0,9 (tabela 4.18).

Ponieważ podobnie jak w przypadku wyrównywania wykładniczego dla wszystkich statków powietrznych błędy prognoz są zbyt duże (MAPE około 20-30%), przeprowadzono więc prognozowanie dla zmiennej dotyczącej napraw płatowca. Wykres autokorelacji przedstawiono na rys 4.54, natomiast wartości współczynników w tabeli 4.19.




Rys. 4.54: Wykres współczynników autokorelacji i autokorelacji cząstkowej zmiennej Płatowiec.

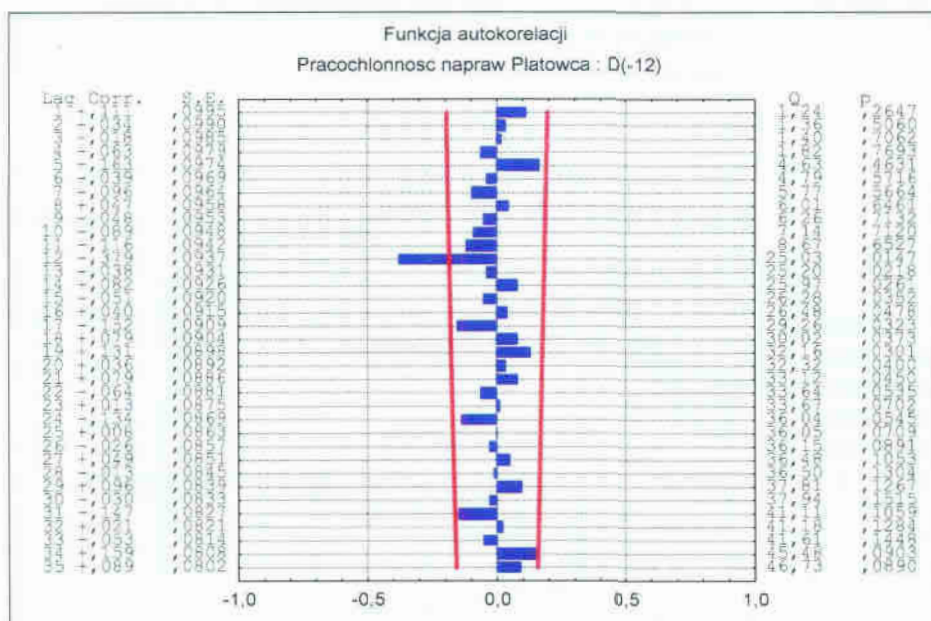
Tabela 4.19: Współczynniki ACF dla zmiennej Płatowiec.

Opóźnienie (w miesiącach)	Współczynnik autokorelacji	Opóźnienie (w miesiącach)	Współczynnik autokorelacji	Opóźnienie (w miesiącach)	Współczynnik autokorelacji
1	0,540312	13	0,423159	25	0,335927
2	0,295826	14	0,250146	26	0,158046
3	0,123610	15	0,063266	27	0,059595
4	-0,064406	16	-0,081621	28	-0,101573
5	-0,080325	17	-0,147646	29	-0,104178
6	-0,157193	18	-0,134091	30	-0,185702
7	-0,155738	19	-0,143646	31	-0,267746
8	-0,038106	20	-0,059041	32	-0,134002
9	0,093836	21	0,045051	33	-0,061527
10	0,194674	22	0,163951	34	0,193864
11	0,428960	23	0,383574	35	0,308314
12	0,542830	24	0,389803	36	0,294719

Wartości współczynników ACF są wyraźnie zaznaczone dla okresu 12, 24, 36 świadczy to o konieczności zróżnicowania szeregu. Należy zatem przed prognozowaniem poddać szereg różnicowaniu.



Rys. 4.55: Wykres zmiennej Płatowiec po różnicowaniu.




Rys. 4.56: Wykres współczynników autokorelacji zmiennej Płatowiec po różnicowaniu.

Przedstawione powyżej wykresy świadczą o konieczności zróżnicowania szeregu przed prognozowaniem.

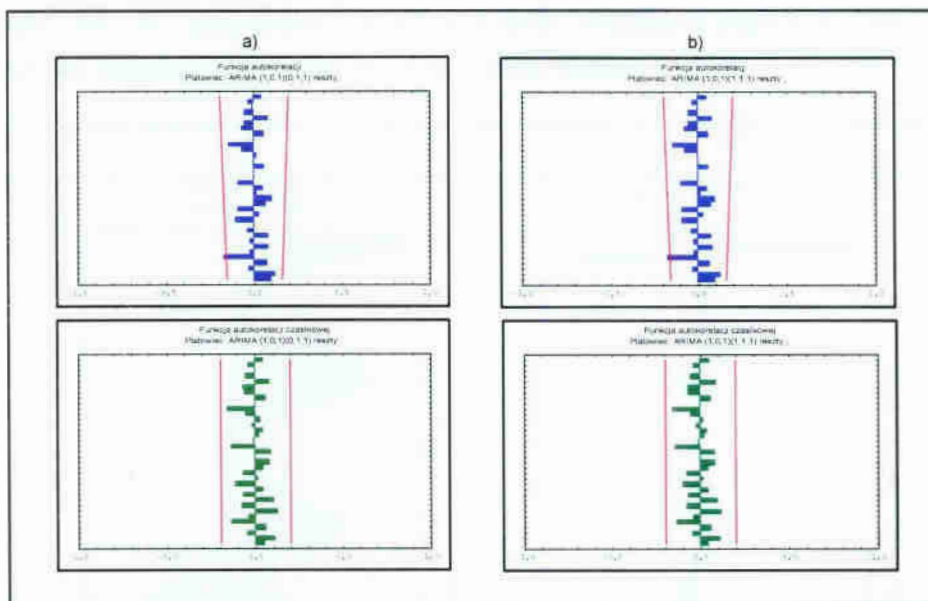
Tabela 4.20: Wyniki prognozy dla zmiennej Płatowiec przy danych nie przekształconych.

MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	I^2
(0,0,0)(1,1,0)	13451	1121	12,31%	86,2%	8,3%	4,9%	86,8%	0,0508
(0,0,0)(2,1,0)	5088	424	10,33%	78,6%	8,3%	4,5%	87,2%	0,0192
(0,0,0)(0,1,1)	14713	1226	9,74%	80,1%	8,3%	4,4%	87,3%	0,0556
(0,0,0)(0,1,2)	13670	1139	9,82%	80,0%	8,3%	4,9%	86,8%	0,0516
(1,0,1)(2,1,0)	506	42	11,53%	71,3%	8,3%	13,3%	78,4%	0,0019
(1,0,1)(0,1,1)	1755	146	7,14%	68,4%	8,3%	29,5%	62,2%	0,0066
(1,0,1)(1,1,1)	1840	153	6,24%	68,3%	8,3%	23,3%	68,3%	0,0070
(0,0,0)(1,1,0)	13451	1121	12,31%	86,2%	8,3%	4,9%	86,8%	0,0508

Podobnie jak w przypadku wyrównywania wykładniczego, po podzieleniu statków powietrznych na podzespoły uzyskano bardziej dokładne prognozy. Błędy prognoz osiągają wartość od 6,24 do 12,31%. Najbardziej trafne okazały się dwa modele (zaznaczone w tabeli 4.20): (1,0,1)(0,1,1) (przy błędzie MAPE - 7,14%) oraz (1,0,1)(1,1,1) (błąd MAPE - 6,24%). Brak autokorelacji reszt modelu świadczy o ich poprawności (rys 4.58). Różnica w dokładności prognoz w porównaniu do pracochności napraw (SP) zauważalna jest również na wykresie (rys 4.57).




Rys. 4.57: Prognozy dla zmiennej Płatowiec w 2000 r (modele ARIMA).




Rys. 4.58: Wykresy współczynników autokorelacji reszt i autokorelacji częściowej wybranych modeli prognozy dla zmiennej Płatowiec w przypadku danych z 9 lat: a) autokorelacja reszt i autokorelacja częściowa modelu (1,0,1)(0,1,1) b) autokorelacja reszt i autokorelacja częściowa modelu (1,0,1)(1,1,1).

Na przykładzie uzyskanych modeli dokonano prognozowania (ze wszystkich danych dotyczących pracochłonności napraw płatowca) na lata 2001-2002, a wyniki przedstawiono na rys 4.59.



Rys. 4.59: Prognozy dla zmiennej Płatowiec w latach 2001 –2002 (modele ARIMA).

Podobnie jak w przypadku wyrównywania wykładniczego zmienną dotyczącą pracochłonności napraw płatowców przekształcono filtrem 4253H.




Rys. 4.60: Wykres współczynników a) autokorelacji reszt; b) autokorelacji cząstkowej reszt zmiennej Płatowiec przy danych z 9 lat przekształconych filtrem 4253H.

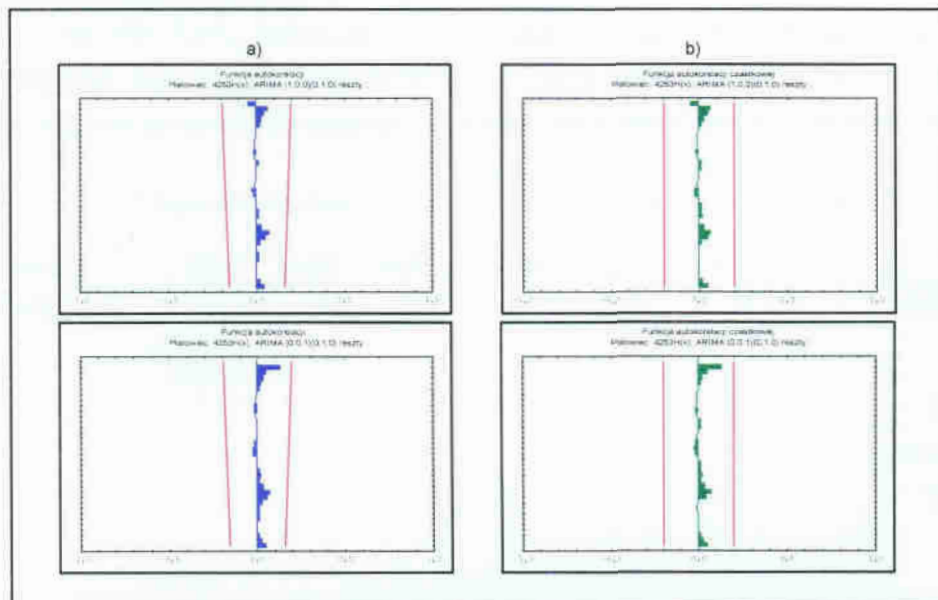
Wyniki prognoz przekształconej zmiennej przedstawiono w tabeli 4.21 i na wykresie 4.61. Przed prognozowaniem konieczne było przekształcenie logarymiczne szeregu. Uzyskano dwa modele. Błędy MAPE osiągnęły wartość 10,15%, natomiast współczynnik rozbieżności Theila 0,02.

Tabela 4.21: Wyniki prognozy dla zmiennej *Platowiec* przy danych przefiltrowanych 4253H.

MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	I^2
(1,0,0)(0,1,0)	6154	513	10,15%	93,0%	8,3%	33,9%	57,8%	0,0233
(0,0,1)(0,1,0)	5741	478	10,15%	94,3%	8,3%	37,2%	54,5%	0,0217

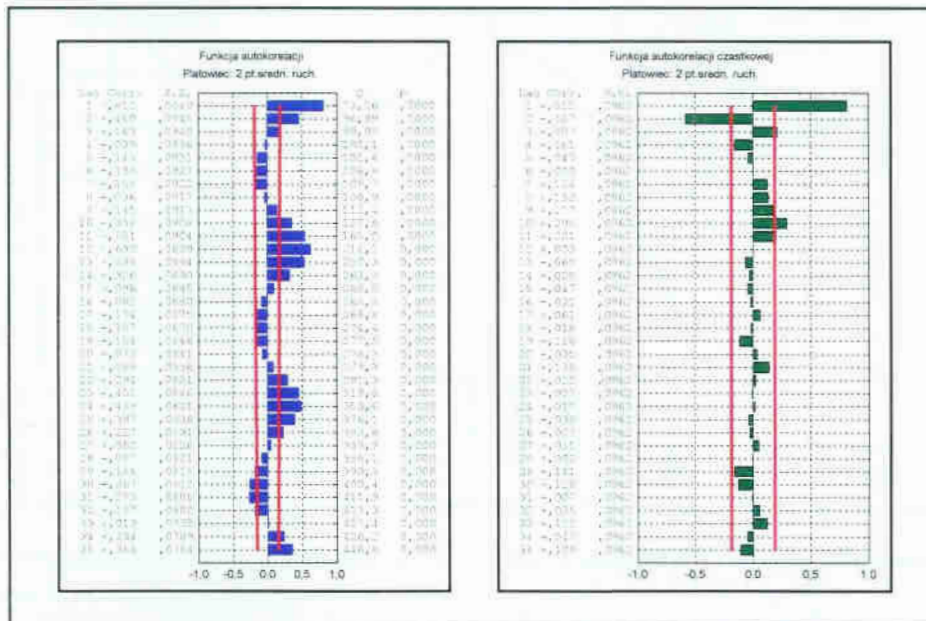


Rys. 4.61: Prognozy dla zmiennej *Platowiec* w 2000 r w przypadku szeregu przekształconego filtrem 4253H (modele ARIMA).



Rys. 4.62: Wykres współczynników autokorelacji reszt wybranych modeli zmiennej *Pracochłonność* w przypadku danych z 9 lat przekształconych filtrem 4253H: a) autokorelacja reszt i autokorelacja cząstkowa reszt modelu (1,0,0)(0,1,0) b) autokorelacja reszt i autokorelacja cząstkowa reszt modelu (0,0,1)(0,1,0).

Dane dotyczące pracochłonności napraw płatowca z 9 lat przekształcono przy pomocy średniej ruchomej $N=2$ punktowej i obliczono prognozy dla przekształconego szeregu.




Rys. 4.63: Wykres współczynników autokorelacji zmiennej Płatowiec w przypadku danych z 9 lat przekształconych $N=2$ punktową średnią ruchomą.

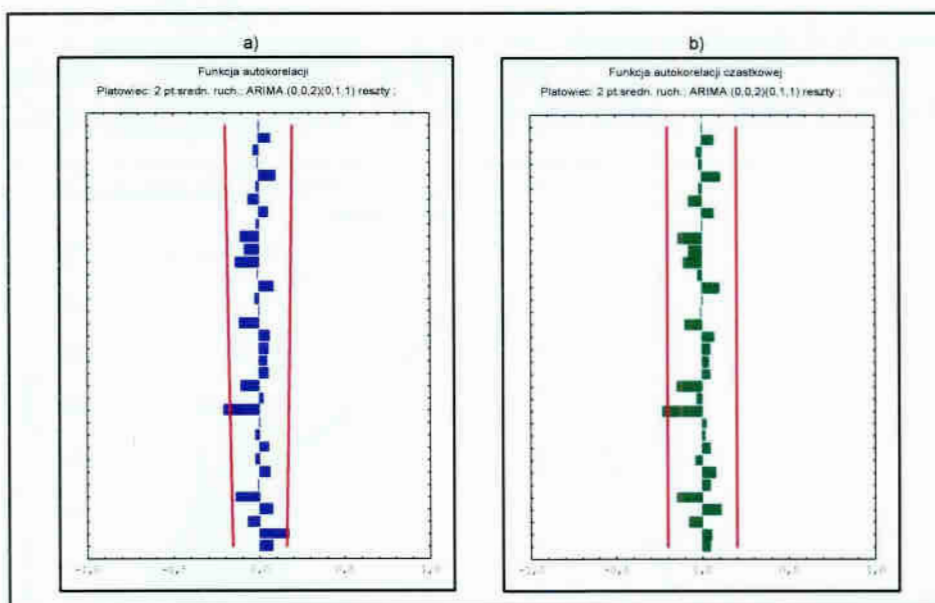
Kolejno powiększano parametry p , q , ps , qs . Nie było konieczne przekształcenie logarytmiczne szeregu. Uzyskano model $(0,0,2)(0,1,1)$. Błędy prognozy przedstawiono w tabeli 4.21 i na rys 4.64, natomiast wykres autokorelacji reszt modelu na rys 4.65. Charakterystyczne jest to, że błąd MAPE osiąga wartość 16,88%. W porównaniu z wartościami błędów prognoz dla szeregu nie przekształconego jest to olbrzymia różnica.

Tabela 4.22: Prognoza dla zmiennej Płatowiec przy danych przekształconych $N=2$ pt. średn. ruch.

MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	I^2
(0,0,2)(0,1,1)	12726	1061	16,88%	12,8%	8,3%	16,1%	75,6%	0,0481




Rys. 4.64: Prognoza dla zmiennej Płatowiec w 2000 r w przypadku szeregu przekształconego N-2 pt. średn. ruch. oraz modelu ARIMA (0,0,2)(0,1,1).



Rys. 4.65: Wykres współczynników a) autokorelacji reszt zmiennej Płatowiec w przypadku danych z 9 lat przekształconych N-2 punktową średnią ruchomą oraz modelu (0,0,2)(0,1,1) b) autokorelacja cząstkowa reszt w przypadku modelu (0,0,2)(0,1,1).


Dane pracochłonności napraw płatowca z 9 lat przekształcono przy pomocy mediany ruchomej $N=3$ punktowej i obliczono prognozy w przypadku tak przekształconego szeregu. Nie było konieczne przekształcenie logarytmiczne szeregu przed prognozowaniem. Po zróżnicowaniu sezonowym szeregu uzyskano model (0,0,2)(0,1,1). Również w tym przypadku (podobnie jak dla szeregu przekształconego N-2 pt. średn. ruch.) błąd prognozy MAPE wynosi aż 16,28%.



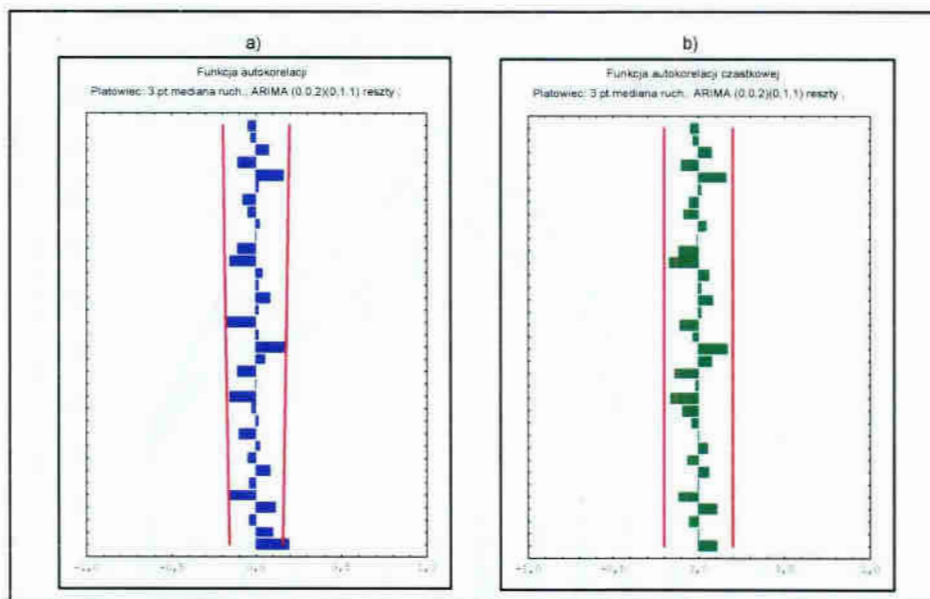
Rys. 4.66: Wykres współczynników autokorelacji i autokorelacji cząstkowej zmiennej Płatowiec w przypadku danych z 9 lat przekształconych medianą ruchomą N-3 punktową.

Tabela 4.23: Prognoza dla zmiennej Płatowiec przy danych przekształc. N-3 pt. medianą ruch.

MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	I^2
$(0,0,2)(0,1,1)$	12593	1049	16,28%	51,6%	8,3%	5,9%	85,8%	0,0476



Rys. 4.67: Prognoza dla zmiennej Pracochłonność w 2000 r w przypadku szeregu przekształconego N-3 pt. medianą ruch. oraz modelu ARIMA $(0,0,2)(0,1,1)$.




Rys. 4.68: Wykres współczynników autokorelacji reszt modeli zmiennej Płatowiec w przypadku danych z 9 lat przekształconych medianą ruchomą N-3 punktową a) w modelu $(0,0,2)(0,1,1)$ b) w modelu $(0,0,2)(0,1,1)$.

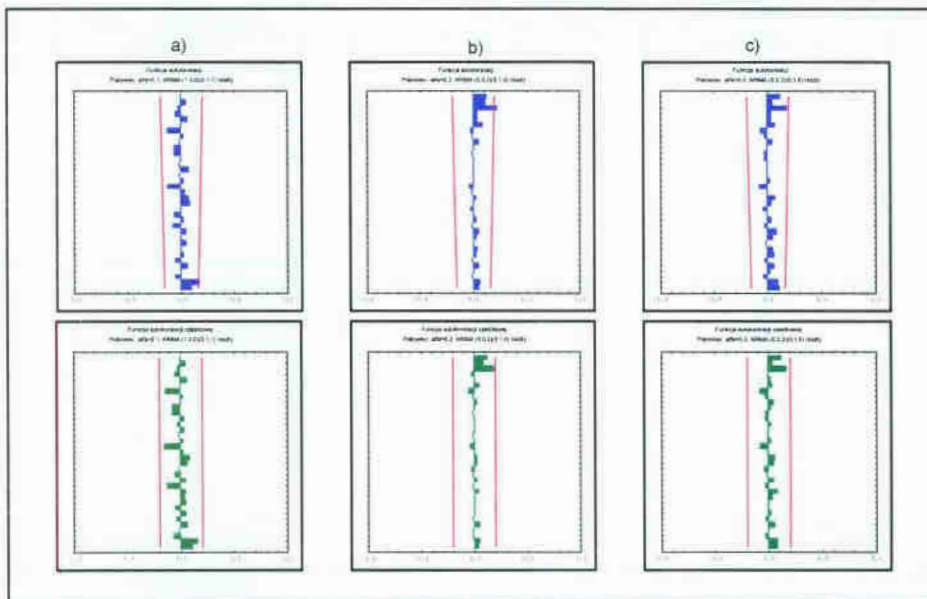
Podczas wygładzania szeregu pracochłonność napraw płatowca przy $\alpha=0,1$ oraz $\alpha=0,8 \div 0,9$ nie było konieczne dokonanie przekształcenia logarymicznego przy prognozowaniu. W pozostałych przypadkach szeregi przekształcono. Wraz ze zwiększaniem współczynnika alfa uzyskiwano mniejsze błędy MAPE. Świadczy to o braku konieczności wygładzania szeregu. W tabeli 4.24 przedstawiono wyniki prognoz w zależności od współczynnika alfa, na rys 4.69 prognozy, natomiast na rys 4.70÷4.72 współczynniki autokorelacji i autokorelacji cząstkowej reszt modeli ARIMA.

Tabela 4.24: Prognoza dla zmiennej Płatowiec przy danych wygładzonych oraz $\alpha=0,1 \div 0,9$.

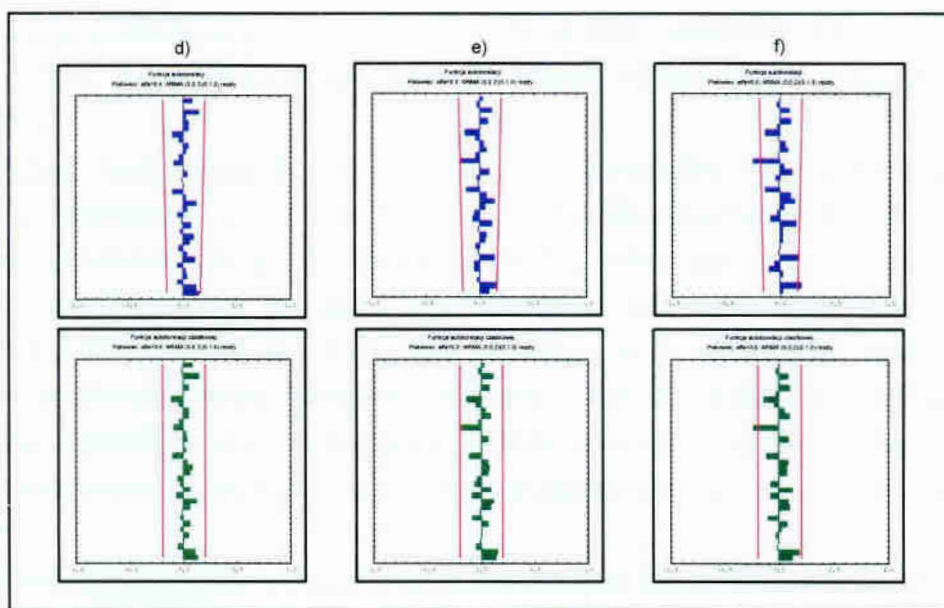
Alfa	MODEL	SSE	MSE	MAPE	SS	U_1	U_2	U_3	i^2	Wykresy reszt na rys. 4.70-4.72
0,1	$(1,0,0)(0,1,1)$	12168	1014	29,00%	12,3%	8,3%	125,0%	-33,4%	0,0460	a)
0,2	$(0,0,2)(0,1,0)$	12638	1053	27,54%	35,4%	8,3%	76,6%	15,1%	0,0477	b)
0,3	$(0,0,2)(0,1,0)$	11845	987	24,05%	49,8%	8,3%	50,6%	41,0%	0,0448	c)
0,4	$(0,0,2)(0,1,0)$	11315	943	19,75%	54,4%	8,3%	31,9%	59,8%	0,0428	d)
0,5	$(0,0,2)(0,1,0)$	12144	1012	15,70%	64,9%	8,3%	16,4%	75,2%	0,0459	e)
0,6	$(0,0,2)(0,1,0)$	12932	1078	13,35%	77,2%	8,3%	8,2%	83,4%	0,0489	f)
0,7	$(0,0,1)(0,1,0)$	12249	1021	10,78%	92,5%	8,3%	5,1%	86,5%	0,0463	g)
0,8	$(0,0,0)(0,1,1)$	12797	1066	10,10%	82,3%	8,3%	9,3%	82,3%	0,0483	h)
0,9	$(0,0,0)(0,1,1)$	13707	1142	9,26%	81,1%	8,3%	6,4%	85,3%	0,0518	i)



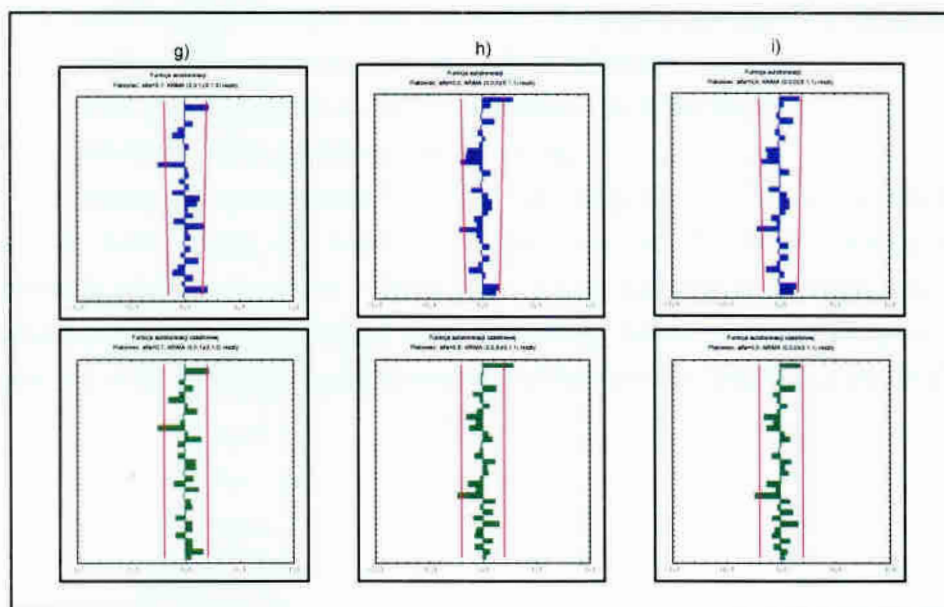
Rys. 4.69: Prognozy otrzymane za pomocą modeli ARIMA dla zmiennej Płatowiec w 2000 r w przypadku szeregu przekształconego wygładzaniem przy alfa z przedziału $0,1 \div 0,9$.



Rys. 4.70: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej modeli zmiennej Płatowiec w przypadku danych z 9 lat w zależności od alfa z przedziału $0,1 \div 0,3$ (tabela 4.24).



Rys. 4.71: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej modeli zmiennej Płatowiec w przypadku danych z 9 lat w zależności od alfa z przedziału $0,4 \div 0,6$ (tabela 4.24).



Rys. 4.72: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej modeli zmiennej Płatowiec w przypadku danych z 9 lat w zależności od alfa z przedziału $0,7 \div 0,9$ (tabela 4.25).

4.3. Wnioski

Uzyskane wyniki wskazują jednoznacznie na konieczność podziału statków powietrznych na podzespoły. Umożliwia to osiągnięcie mniejszych wartości błędów prognoz.

W przypadku wyrównywania wykładniczego najmniejsze błędy, tzn. najbardziej trafne prognozy, dotyczące pracochłonności napraw statków powietrznych uzyskano po przekształceniu szeregu. W przypadku szeregu nie przekształconego w metodzie

wyrównywania wykładniczego błąd MAPE wyniósł 36%, natomiast w przypadku metody ARIMA - 28%. Po przekształceniu szeregu filtrem 4253H błędy prognozy osiągnęły wartość 24%.

Najbardziej trafne okazały się prognozy w przypadku pracochłonności napraw płatowca, w których błędy MAPE wyniosły 6-7% dla wyrównywania wykładniczego szeregu nie przekształconego. Modelami ARIMA, które nie ustępują, jeśli chodzi o dokładność prognozowania metodzie wyrównywania wykładniczego, okazały się dwa modele: $(1,0,1)(0,1,1)$ oraz $(1,0,1)(1,1,1)$. Świadczy to o możliwości wykorzystania i uzyskania porównywalnych prognoz dla obu metod. Jedynym problemem, jak wspomniano wcześniej jest to, że technika ARIMA wymaga znacznej wiedzy prognosty o sposobach szacowania modeli nieliniowych, współczynników autokorelacji i autokorelacji cząstkowej.

Przeprowadzona analiza wykazała, że jednoznacznie jest trudno określić (w przypadku całkowitej pracochłonności napraw (SP)) zależności występujących w szeregu. Większą trafność prognoz można byłoby uzyskać po wprowadzeniu dodatkowych zmiennych opisujących jak np.:

- ilość zaplanowanych „dni lotnych” w danym miesiącu i w danym roku;
- ilość zrealizowanych „dni lotnych w miesiącu;
- ilość godzin nalotu w danym miesiącu i w skali roku;
- dokładny wiek statków powietrznych;
- rodzaj wykonywanych lotów np. loty na poligon, na walki powietrzne;

Przydatnym narzędziem do prognozowania powyższych danych mogą okazać się jednokierunkowe sieci neuronowe – głównie z uwagi na charakteryzującą je możliwość opisu zależności nieliniowych. Należy zwrócić uwagę na to, że błędy prognoz nie muszą być mniejsze niż w przypadku wyrównywania wykładniczego, bądź metody ARIMA.

ROZDZIAŁ 5

PROGNOZA PRACOCHOŁONNOŚCI NAPRAW PRZY WYKORZYSTANIU SZTUCZNYCH SIECI NEURONOWYCH

5.1. Ogólna charakterystyka sieci neuronowych

W 1943 roku opracowany został przez McCullocha i Pittsa [Kor1994] matematyczny model sztucznego neuronu. Podobnie jak w neuronie biologicznym dochodziło do niego wiele połączeń i wychodziło jedno, uaktywniane po przekroczeniu wartości progowej. W 1949 roku Hebb wyjaśnił mechanizm pamiętania informacji w biologicznych sieciach neuronowych, natomiast w 1958 Rosenblatt opracował i zbudował pierwszą sztuczną sieć neuronową zwaną perceptronem. Sieć służyła do rozpoznawania znaków alfanumerycznych. Wadą perceptronów była możliwość rozwiązywania jedynie problemów klasyfikacji separowalnych liniowo w warstwie wyjściowej. W 1969 roku Minsky i Papert opublikowali książkę pt. „Perceptrons”, w której udowodnili liczne ograniczenia sieci jednowarstwowej (perceptronu). Tragiczna śmierć Rosenblatt’a w 1971 roku oraz ww. publikacja były przyczyną zaprzestania badań nad sieciami neuronowymi, aż do połowy lat osiemdziesiątych 20-go wieku. W 1986 roku ukazał się artykuł Rumelharta, Hintona i Wiliamsa pt. „Learning Internal Representation by Error Propagation”, opisujący działanie algorytmu propagacji błędu, który znosi większość wad perceptronu wskazanych przez Minsky’ego i Papert’a.

Według [Zie2000] „*sztuczna sieć neuronowa jest systemem wzajemnie połączonych prostych elementów przetwarzających informacje, zwanych neuronami, jednostkami lub węzłami. Do połączeń między elementami są przyporządkowane współczynniki wagowe, określające siłę powiązań i tworzące zbiór parametrów modelu*”. Informacją może być m.in. pracochłonność napraw statków powietrznych.

Do zalet współczesnych sztucznych sieci neuronowych (SNN) należy [Rej2002]:

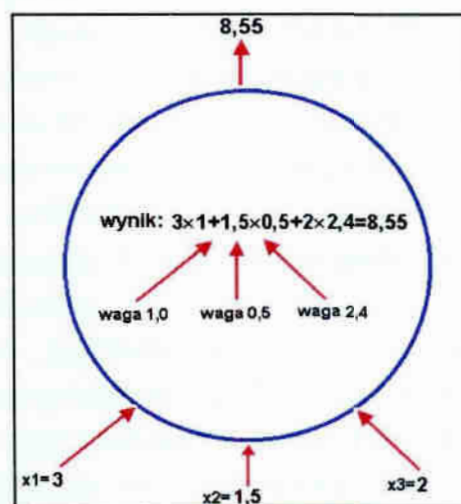
- możliwość samoczynnego programowania się sieci w trakcie procesu uczenia,
- zdolność do uogólniania posiadanej wiedzy,
- duża odporność na błędy pomiarowe.

Charakterystyczną cechą sieci neuronowych jest odporność na przypadkowe uszkodzenia np. wyłączenie na drodze programowej neuronu, nie powoduje całkowitego uszkodzenia układu. W takim przypadku sieć potrafi się adoptować i działać nadal poprawnie. Jest to pewne podobieństwo do systemów biologicznych, w których funkcje uszkodzonego organu niekiedy przejmują częściowo inne organy [Mic2000].

Sztuczna sieć neuronowa jest zespołem połączonych ze sobą neuronów. Poszczególne neurony mają jedno złącze wyjściowe i przynajmniej jedno wejściowe (rys. 5.1). Każda sieć powinna składać się przynajmniej z dwóch warstw – wejściowej i wyjściowej; zazwyczaj też między nimi znajdują się warstwy pośrednie. Podstawowym parametrem wpływającym na sposób funkcjonowania neuronu są współczynniki zwane *wagami*. Przetwarzanie informacji przez neuron można podzielić na dwa etapy:

- agregacja danych wejściowych (polegająca na przetworzeniu wektora wejściowego w pojedynczą wartość – zagregowaną wartość wejściową),
- wyznaczenie wartości wyjściowej neuronu, które uzależnione jest od funkcji aktywacji, przekształcającej wcześniej zagregowaną wartość wejściową w wartość wyjściową neuronu.

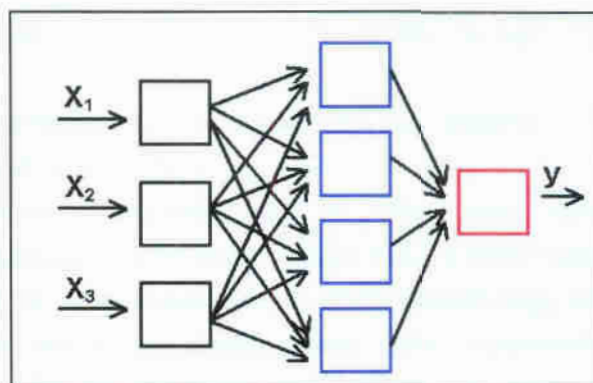
Agregacji danych wejściowych można dokonać poprzez zsumowanie iloczynów wartości wejściowych x_1, x_2, \dots, x_n i odpowiadających im wag (rys. 5.1). Neurony takie nazywa się liniowymi. Inną metodą agregacji jest obliczenie kwadratu odległości Euklidesa pomiędzy wektorem wejściowym x i wektorem wag w . Neurony nazywa się wtedy neuronami radialnymi.



Rys. 5.1: Schemat budowy neuronu.

Wyznaczenie wartości wyjściowej neuronu może odbywać się poprzez wykorzystanie następujących funkcji aktywacji [Tad2000]:

- funkcja liniowa: na wyjściu neuronu pojawia się zagregowana wartość wejściowa pomnożona przez pewien stały współczynnik,
- *funkcja sigmoidalna: o wartościach z przedziału od 0 do 1,*
- funkcja tangensoidalna: o wartościach z przedziału od -1 do +1,
- funkcja gaussowska: generująca maksymalną wartość wyjściową przy zerowej wartości argumentu, natomiast wraz ze zwiększaniem zagregowanej wartości wejściowej wartość wyjściowa tak funkcjonującego neuronu maleje.



Rys. 5.2: Przykładowa sztuczna sieć neuronowa.

Neurony w sieciach tworzą warstwy, które można podzielić na:

- warstwy wejściowe, których zadaniem jest gromadzenie sygnałów wejściowych,
- warstwy wyjściowe, przetwarzające sygnały z warstwy wejściowej i ukrytej,
- warstwy ukryte, znajdujące się pomiędzy warstwami wejściowymi i wyjściowymi, mające za zadanie przetwarzanie sygnałów z warstwy wejściowej.

Sieci neuronowe znajdują zastosowanie w wielu dziedzinach życia. Mogą rozwiązywać problemy klasyfikacyjne i regresyjne. Używa się ich również m.in. do modelowania i prognozowania szeregów czasowych. Jest to związane z tym, że w większości szeregów czasowych zależności w nich występujące mają charakter nieliniowy. Do modelowania wymagane jest więc zastosowanie modeli nieliniowych. Zdolność do aproksymacji dowolnych zależności nieliniowych oraz zdolności generalizujące posiadają jednokierunkowe sieci neuronowe. Ponadto, w przypadku pojawienia się nowych danych istnieje możliwość douczenia sieci.

Według [Lul2000] w przypadku problemów klasyfikacyjnych sieć pozwala klasyfikować obiekty do odpowiednich klas. Rozróżnia się klasyfikację wzorcową, której wzorce klas znane są przed rozpoczęciem badań oraz klasyfikację bezwzorcową.

W problemach regresyjnych sieć neuronowa stanowi narzędzie umożliwiające opisywanie zależności pomiędzy zmiennymi. Z reguły przyjmuje się że zmienne objaśniane mają charakter ciągły.

Z punktu widzenia zastosowanej architektury w SSN, można je podzielić na klasy [Tad2000]:

- jednokierunkowe, posiadające warstwową budowę, z wyraźnie zaznaczoną warstwą wejściową do pobierania sygnałów z otoczenia oraz warstwą wyjściową do wyprowadzania z sieci przetworzonych w niej sygnałów,
- rekurencyjne, których cechą charakterystyczną jest występowanie sprzężeń zwrotnych między poszczególnymi warstwami, „informacja pojawiająca się w sieci nie jest wysyłana na zewnątrz po jednorazowym przetworzeniu w każdej z warstw, lecz oscyluje między warstwami lub w ich obrębie, aż do spełnienia

pewnego kryterium zbieżności i dopiero wtedy zostaje przekazana na wyjście sieci”,

- komórkowe, opierające swoje działanie na pojęciu fizycznego sąsiedztwa występujących w nich neuronów.

Sieci jednokierunkowe nazywane są w literaturze również perceptronami wielowarstwowymi i oznaczane są w skrócie jako MLP (*Multi-Layer Perceptrons*). SSN MLP charakteryzują się tym, że połączenia w SSN umożliwiają komunikację pomiędzy neuronami znajdującymi się w sąsiadujących ze sobą warstwach. Ponadto wszystkie neurony wchodzące w skład sieci dokonują agregacji danych wejściowych poprzez wyznaczenie sumy ważonych wejść. Uczenie perceptronów wielowarstwowych m. in.:

- *polega na wyznaczeniu minimum funkcji błędu, przy wykorzystaniu technik opartych na gradiencie (metoda wstecznej propagacji błędów) hesjanie (metoda Newtona, Lavenberga-Marquardta) lub na przybliżeniu odwrotności hesjanu (metoda quasi-newtonowska),*
- stosowany jest tryb uczenia z nadzorem,
- czas uczenia jest stosunkowo długi w porównaniu z uczeniem innych modeli SSN.

Zaletą sieci MLP jest krótki czas uruchamiania oraz niewielkie zapotrzebowanie na pamięć ze względu na prostą konstrukcję. Najwięcej trudności sprawia określenie ilości warstw i liczby neuronów w warstwach ukrytych.

Innym rodzajem sieci stosowanym w predykcji są sieci o radialnych funkcjach bazowych RBF (*Radial Basis Function Networks*). Podobnie jak sieci MLP posiadają strukturę warstwową, lecz tylko dokładnie jedną warstwę ukrytą. W neuronach warstwy ukrytej dokonywana jest agregacja danych wejściowych poprzez wyznaczenie odległości pomiędzy wektorem wejściowym a wektorem wag. Wyznaczona w ten sposób zagregowana wartość wejściowa staje się parametrem funkcji aktywacji. Najczęściej używa się funkcji gaussowskich (dzwonowych). Ich cechą jest to, że wartość wyjściowa neuronu ukrytego jest tym większa, im większe było podobieństwo wektora wejściowego do wektora wag neuronu. Ponadto wartości wyjściowe neuronów ukrytych są agregowane przez neurony warstwy wyjściowej, która wyznacza wartość wyjściową sieci przy pomocy liniowej funkcji aktywacji. Konstruktor sieci ma za zadanie określenie wag neuronów ukrytych. W sytuacji gdy liczba neuronów ukrytych jest równa liczbie elementów uczących, w charakterze wag wykorzystuje się wektory wejściowe poszczególnych wzorców. Jeśli liczba elementów uczących jest większa od liczby neuronów, posiadany zbiór dzieli się na skupienia. Liczba skupień powinna być równa liczbie neuronów uczących. Wagi neuronów określa się jako równe środkom ciężkości poszczególnych grup. Następnie należy określić kształt funkcji aktywacji. Czynnikiem wpływającym na kształt funkcji aktywacji jest rozkład punktów reprezentujących skupienia występujące w danych. Po wprowadzeniu danych wejściowych do sieci na wyjściach neuronów ukrytych pojawiają się wartości świadczące o stopniu podobieństwa wektora wejściowego do poszczególnych skupień. Ostatnim etapem uczenia sieci jest określenie wag sieci

wyjściowej. Wartości wag wyznaczane są bezpośrednio, a nie w sposób iteracyjny, ze względu na liniowy charakter neuronów wyjściowych. Zaletą sieci RBF jest krótki czas uczenia w porównaniu z sieciami MLP.

Do sieci wykorzystywanych w predykcji używa się również sieci realizujących regresję uogólnioną GRNN (*General Regression Neural Network*). Sieć GRNN zbudowana jest z czterech warstw: wejściowej, dwóch warstw ukrytych oraz wyjściowej. Budowa pierwszej warstwy ukrytej jest podobna do warstwy ukrytej w sieci RBF. Neurony w pierwszej warstwie ukrytej modelują funkcje gaussowskie ulokowane nad elementami zbioru uczącego, a ich najwyższa wartość wyjściowa odpowiada punktom zajmowanym przez elementy zbioru uczącego. Wraz z oddalaniem się od wektorów reprezentowanych przez wagi, wartość ta maleje. Wartość wyjściowa sieci jest średnią ważoną ze wszystkich wartości wyjściowych neuronów wchodzących w skład danych uczących. Poszczególne wartości wyjściowe są przemnażane przez wagi. Wykorzystywana jest do tego wartość funkcji gaussowskiej odpowiadającej danemu elementowi zbioru uczącego w punkcie odpowiadającym wektorowi wejściowemu sieci. Następnie obliczana jest ważona suma wartości wyjściowych ze składu uczącego oraz sumy wag. Za wyznaczenie tych wartości odpowiedzialne są neurony drugiej warstwy ukrytej. Wartością wyjściową sieci jest iloraz wspomnianych wartości. Uczenie sieci GRNN składa się z następujących etapów:

- przekopiowanie wektorów wejściowych ze zbioru uczącego do neuronów ukrytych,
- optymalizacja kształtów funkcji gaussowskich,
- określenie współczynników wagowych pozostałych warstw w sposób umożliwiający wyznaczenie średniej ważonej.

Zaletą sieci GRNN jest krótki czas uczenia, jednak sieci te mają bardzo duże rozmiary. Co więcej, w celu wyznaczenia wartości wyjściowej sieci konieczne jest przetworzenie całego zbioru uczącego.

O możliwościach i właściwościach sieci decydują wartości współczynników wagowych neuronów składających się na sieć oraz struktura sieci, na którą składają się: liczba warstw, liczba neuronów w poszczególnych warstwach, sposób połączeń neuronów oraz przyjęty model neuronu.

Dobór wartości wag sieci neuronowej nazywa się uczeniem sieci, gwarantującym uzyskanie wybranego kryterium nauczania. Proces uczenia może być przeprowadzony z nadzorowaniem, czyli uczenie z nauczycielem lub bez nadzorowania - uczenie bez nauczyciela. Tryb uczenia bez nadzoru stosowany jest przy tworzeniu modeli rozwiązujących zagadnienia klasyfikacji bezwzorcowej [Lul2000]. W przypadku tego trybu w skład zbioru uczącego wchodzi jedynie wejściowe zestawy danych. Zbiór uczący nie zawiera informacji na temat wartości pożądaných na wyjściu sieci. *Uczenie sieci jest zakończone, gdy w trakcie kolejnych prezentacji przypadków uczących nie zachodzą zmiany w sposobie przyporządkowania obiektów do właściwych grup.* Uczenie sieci z nadzorem jest stosowane do modelowania systemów rzeczywistych. Zadaniem

nadzorującego jest nauczenie sieci poprawnego reagowania na prezentowane jej sygnałów wejściowych. Celem uczenia jest osiągnięcie średniego lub sumarycznego kwadratowego błędu popełnianego przez sieć. Błąd sieci określany jest jako:

$$b = y_u - y_s, \quad (5.1)$$

gdzie: b - błąd popełniony przez sieć,
 y_u - pożądana odpowiedź sieci na dany zestaw sygnałów wejściowych,
 y_s - rzeczywista odpowiedź sieci na dany zestaw sygnałów wejściowych.

Dla sieci zawierających jeden neuron wyjściowy, funkcja błędu przyjmuje postać:

$$B = \frac{1}{2} \sum_{i=1}^n (y'_u - y'_s)^2, \quad (5.2)$$


gdzie: B - jest funkcją błędu sieci neuronowej;
 n - liczba przykładów uczących.

Do modelowania i prognozowania stosowane są sieci konstruowane w trybie z nadzorem, ponieważ stanowią „dogodne narzędzie opisu zależności pomiędzy różnymi zmiennymi lub pomiędzy oddalonymi w czasie wartościami tej samej zmiennej. Utworzenie prawidłowo funkcjonującego modelu wymaga zastosowania właściwie przygotowanej sieci. W trakcie treningu błąd uczenia nie może stanowić podstawy do oceny sieci, gdyż jego wartość może zostać sprowadzona do dowolnie niskiego poziomu poprzez rozbudowę części ukrytej sieci [Lul2000]. Jednak również nie jest wskazane nadmierne zwiększanie liczby neuronów ukrytych, ponieważ każdy dodatkowy neuron powoduje zwiększenie liczby parametrów swobodnych modelu, co może prowadzić do utraty przez sieć zdolności do generalizacji, czyli braku umiejętności wyznaczania prawidłowej odpowiedzi dla danych wejściowych nie prezentowanych w trakcie uczenia. Zanik zdolności do generalizacji (w trakcie uczenia) nazywany jest przeuczeniem sieci. W przypadku przeuczenia sieci, występuje zmniejszanie się błędu sieci wyznaczonego na podstawie zbioru uczącego, jednak równocześnie występuje coraz gorsze działanie sieci przy danych nie należących do zbioru uczącego. Aby przeciwdziałać temu, stosuje się procedury odpowiedzialne za wczesne wykrycie zaniku zdolności do generalizacji. Odbywa się to w ten sposób, że posiadany zbiór danych dzielony jest na trzy części:

- zbiór uczący, który służy do uczenia sieci i modyfikacji wartości parametrów;
- zbiór walidacyjny, mający za zadanie obserwację procesu uczenia sieci;
- zbiór testowy, służący do ostatecznej weryfikacji uzyskanej sieci.

Przeuczenie sieci ma miejsce wtedy, gdy błąd wyznaczony na podstawie zbioru uczącego zmniejsza się w kolejnych epokach, natomiast błąd walidacyjny początkowo maleje, a następnie jego wartość zwiększa się. W takim przypadku celowe jest przerwanie procesu uczenia, zmniejszenie liczby neuronów ukrytych i ponowne rozpoczęcie uczenia sieci. Podczas prawidłowego uczenia wartość błędu uczenia i błędu walidacyjnego

powinna się zmniejszać. Wartość błędu walidacyjnego zazwyczaj jest wyższa niż błędu uczenia w danej epoce. Jeśli wartości obu błędów są na wysokim poziomie, należy zwiększyć liczbę neuronów ukrytych. Cechą modeli przeuczonych jest generowanie prawie idealnych wyników jeśli na wejście sieci wprowadzane są próbki danych ze zbioru uczącego. W przypadku wprowadzenia innych danych uzyskiwane wyniki są znacznie gorsze. W literaturze problemu rozważane są dwa odmienne podejścia do zjawiska przeuczenia. Zjawisko przeuczenia w pierwszym przypadku odnosi się do danych silnie „zasmużonych”. Na rys 5.3 przedstawione zostały wykresy modeli neuronowych tego samego zasmużonego, systemu. Bez wiedzy o wielkości błędu danych niemożliwe jest określenie, który z modeli jest właściwy. Jeśli wartość błędu danych jest niewielka, prawidłowym modelem jest model na drugim wykresie. Jednak pomimo bardzo dobrego dopasowania do danych, model ten nie posiada właściwości interpolacyjnych, pozwalających mu na obliczenie właściwych wyników przy danych wejściowych spoza zbioru uczącego.



Rys. 5.3: Dwa modele neuronowe silnie zasmużonego systemu; a – model nieprzeuczony, b – model przeuczony [Rej2002].

W analizowanym przypadku prognozowania pracochłonności napraw statków powietrznych i płatowców niecelowy jest podział zbioru danych na zbiór uczący i testowy. Jest to związane ze zbyt małą liczbą danych (122 obserwacje). W celu weryfikacji prognoz, podobnie jak w poprzednich rozważaniach dane z ostatnich 12 miesięcy nie będą włączone do uczenia modelu, tylko do porównania trafności prognoz (pozostaje 110 obserwacji). W przypadku tak niewielkiej liczby danych niewłaściwym posunięciem byłoby pozbawienie sieci neuronowej cennej informacji uczącej. Przewidywanie zbyt daleko w przód zawsze będzie odległe od rzeczywistości. Oceny dla następnego roku mogą być w pełni adekwatne, lecz dalsze wybieganie w przód da niepewne rezultaty.

Do uczenia sieci wykorzystywane są różne algorytmy:

- algorytmy inicjalizacyjne, czyli metody mające na celu (zwykle losową) inicjalizację wag przed rozpoczęciem właściwego uczenia,
- algorytmy uczenia z nauczycielem:
 - wsteczna propagacja błędów,
 - gradienty sprzężone,

- metoda Quasi – Newtona,
 - metoda Levenberga – Marquardta,
 - szybka propagacja,
 - Delta – Bar – Delta,
 - pseudoinwersja;
- algorytmy uczenia bez nauczyciela:
- algorytm Kohonena,
 - próbkowanie radialne;
 - algorytm k – średnich.

Z uwagi na to, że w przeprowadzanych badaniach wykorzystywane są różne algorytmy uczenia, w niniejszej pracy zostanie przedstawiony ich skrócony opis.

Do najlepiej znanych metod służących do uczenia sieci neuronowych należy algorytm wstecznej propagacji błędów. Zalicza się on również do grupy metod najbardziej przydatnych. Opracowany został niezależnie przez Werbosa w 1974 r., i ponownie przedstawiony przez Rumelhart'a w 1986 r. Algorytm ten wywodzi się z algorytmu LMS (*Least Mean Squares*) wprowadzonego w latach sześćdziesiątych przez Widrow'a i Hoff'a. Algorytm wstecznej propagacji błędów ma mniejsze wymagania dotyczące pamięci niż większość innych algorytmów i zwykle szybko osiąga akceptowalny poziom błędu, chociaż precyzyjne osiągnięcie minimalnej wartości błędu może być bardzo czasochłonne. Przyjmuje się z zasady, że algorytm ten służy przede wszystkim do uczenia perceptronów wielowarstwowych. W algorytmie wstecznej propagacji błędów, zmiany wag przeprowadzane są po prezentacji każdego kolejnego przypadku wchodzącego w skład każdej epoki.

Zaawansowaną metodą uczenia perceptronów wielowarstwowych jest algorytm gradientów sprzężonych. Jest on szczególnie polecany dla sieci o dużej liczbie wag, więcej niż kilkaset, i dla sieci o wielu neuronach wyjściowych. Algorytm gradientów sprzężonych dokonuje modyfikacji wag w sposób skumulowany. Modyfikacja wag przeprowadzana jest jednorazowo w trakcie realizacji jednej epoki, a więc w inny sposób niż w algorytmie wstecznej propagacji błędów. W trakcie stosowania tego algorytmu na powierzchni błędu wyznaczana jest w każdej epoce uśredniona, względem wszystkich przypadków, wartość gradientu, która stanowi podstawę do jednorazowej modyfikacji wag przeprowadzanej w końcowej fazie każdej epoki.

Dla mniejszych sieci posiadających jedno wyjście zwykle lepszy jest algorytm Levenberga-Marquardta. Przy stosowaniu algorytmu Levenberga-Marquardta rosną wymagania odnośnie zapotrzebowania na pamięć proporcjonalnie do kwadratu liczby wag w sieci. Uniemożliwia to jego użycie w odniesieniu do sieci o dowolnie dużych rozmiarach, posiadających więcej niż kilkaset wag.

Dla sieci o małej liczbie wag, do kilkuset, zaleca się stosowanie metody Quasi – Newtona. Może być ona stosowana wszędzie tam, gdzie stosuje się wsteczną propagację.

W algorytmie Quasi-Newtona wypracowywany jest średni gradient powierzchni błędu, dla wszystkich przypadków, zanim, na końcu epoki zaktualizowane zostaną wszystkie wagi.

W celu szybszego uczenia sieci stosuje się algorytm szybkiej propagacji. Algorytm szybkiej propagacji działa w sposób skumulowany. Szybka propagacja wyznacza średni gradient dla powierzchni błędu na podstawie całego zbioru uczącego i dokonuje jednorazowej modyfikacji wag na końcu każdej epoki.

W odróżnieniu od metody szybkiej propagacji korzystną tendencją do stabilnego działania wykazuje metoda *Delta-Bar-Delta*. Ponadto w pewnych przypadkach, może charakteryzować się wyższą efektywnością, chociaż z kolei może być ona skłonna do zatrzymywania się w minimach lokalnych, w większym stopniu niż wsteczna propagacja błędów. Algorytm działania tej metody jest podobny jak w przypadku algorytmu szybkiej propagacji.

Algorytm pseudoinwersji stosowany jest do określenia wartości wag w ściśle liniowej warstwie wyjściowej sieci neuronowej. Wykorzystuje on liniową technikę dekompozycji według wartości szczególnych do wyznaczenia macierzy pseudoodwrotnej, która potrzebna jest do określenia wartości wag. Uzyskane rozwiązanie charakteryzuje się najmniejszą średnią wartością kwadratów odchyleń.

Po raz pierwszy, opracowania na temat sieci samoorganizujących z konkurencją i sąsiedztwem pojawiły się w latach 70., przy opisie eksperymentów fińskiego badacza Kohonena. Algorytm ten jest stosowany głównie w przypadku sieci Kohonena, jednak można niekiedy go używać do uczenia sieci RBF. Algorytm Kohonena przypisuje centra do ukrytej warstwy radialnej, próbując podczas uczenia bez nauczyciela, rozpoznać skupienia wśród przypadków uczących. Zbliżone do siebie w przestrzeni wzorców centra skupień przypisywane są zwykle do neuronów, które w sieci znajdują się blisko siebie, są uporządkowanie topologiczne. Neurony w sieci Kohonena rozważane są tak, jakby były rozmieszczone w węzłach siatki rozciągającej się w dwóch prostopadłych kierunkach, w związku z dwuwymiarową warstwą radialną. Każdy neuron ma ustaloną pozycję, która wynika z numeru "wiersza" i numeru "kolumny" w której jest on lokalizowany w ramach wspomnianej siatki. Neurony znajdujące się w sąsiednich wierszach i kolumnach rozważane są jako neurony sąsiednie w stosunku do danego neuronu, co ma dość znaczący wpływ na przebieg uczenia sieci. Algorytm testuje każdy przypadek uczący i wybiera dla niego najbliższe centrum, rozpoczynając od początkowych, dobranych losowo centrów – ulokowanych w neuronach radialnych podczas losowego nadawania im początkowych przypadkowych wartości wag. Powoduje to rekrutację neuronu, w którego wagach zapisane jest to centrum. Neuron ten dalej rozważany jest jako "zwycięzca". Zwycięzca oraz jego sąsiedztwo są modyfikowane w taki sposób, aby zapisane w nich centra upodobniły się do przypadku uczącego. W trakcie działania algorytmu stopniowo zmniejszany jest współczynnik uczenia, który kontroluje stopień upodobniania się centrów do przypadków uczących oraz wielkość sąsiedztwa. Na wstępie uczenia, algorytm tworzy w sieci przybliżoną, tzw. mapę topologiczną. Wstępnie lokowane są podobne skupienia

przypadków w określonym obszarze warstwy radialnej, natomiast w ostatnim etapie procesu uczenia mapa topologiczna jest precyzyjnie dostrajana. W końcowym efekcie pojedyncze neurony odpowiadają niewielkim skupieniom podobnych do siebie przypadków wejściowych i tworzą w ten sposób pewne klasy podobieństwa wśród wejściowych danych. Jeśli sąsiedztwo ma wielkość zerową to algorytm realizuje technikę grupowania, czyli znajduje zbiór wektorów wzorcowych, reprezentujących centra grup, i klasyfikuje przypadki zgodnie z podobieństwem do najbliższego wektora wzorcowego. Jeśli rozmiary siatki, w węzłach której rozmieszczone są neurony, zdeformuje się w taki sposób, że powstanie tylko jeden wiersz, to wówczas sieć, mająca wtedy postać łańcucha neuronów, może być stosowana dla rzutowania przypadków z wielowymiarowej przestrzeni wejściowej do jednowymiarowej warstwy neuronów.

Do wyznaczenia wag neuronów znajdujących się w warstwie radialnej służy próbkowanie radialne. Jest to technika prosta, polegająca na tym, że w sposób losowy wybiera się przypadki uczące w liczbie równej liczbie neuronów ukrytych i ich wartości, w sensie wektorów wejściowych przypisuje się wektorom wag neuronów radialnych. Dzięki temu wylosowane przypadki spełniają funkcję centrów radialnych. Ten sposób postępowania jest uzasadniony, jeśli rozkład danych uczących jest reprezentatywny dla problemu, natomiast liczba rzeczywistych skupisk występujących w danych powinna być znacząco mniejsza od liczby zastosowanych neuronów radialnych.

Algorytm *k*-średnich ma za zadanie wyznaczenie centrów radialnych, które przechowywane są w neuronach radialnych znajdujących się w pierwszej warstwie ukrytej sieci. *Metoda k-średnich przypisuje każdy przypadek uczący do jednego z k skupień, gdzie k jest liczbą neuronów radialnych. Każde z wyznaczonych skupień reprezentowane jest przez środek ciężkości należących do niego przypadków, zaś odległość każdego przypadku od środka ciężkości przypisanego mu skupienia jest mniejsza od odległości pomiędzy tym przypadkiem a środkiem ciężkości każdego innego skupienia (jest to podstawowe kryterium zaliczenia określonego przypadku do konkretnego skupienia). Środki ciężkości skupień kopiowane są do neuronów radialnych. Celem działania algorytmu k-średnich jest określenie zbioru centrów skupień, które w najlepszy sposób reprezentują rzeczywisty rozkład przypadków uczących [Sta2000].*

W niniejszej pracy do uczenia SSN wykorzystano algorytm wstecznej propagacji błędów, W celu douczania sieci wykorzystywano metodę gradientów sprzężonych oraz metodę Quasi – Newtona.

Należy nadmienić że do uczenia SSN wykorzystuje się również algorytmy genetyczne, których szczegółowe zastosowanie i opis można znaleźć m.in. w [Kor1994] i [Mas1996].

Niezwykle cenne uwagi przy tworzeniu sieci neuronowych można znaleźć w [Tad2000]. Szczególną uwagę należy zwrócić na dokonanie odpowiedniej analizy szeregu i jego wstępne przygotowanie (preprocessing), zanim nastąpi utworzenie sieci. Algorytm postępowania przy budowie modeli neuronowych do prognozowania szeregów jest następujący:

- preprocessing:
 - badanie poprawności danych,
 - operacjonalizacja danych,
 - wstępne określenie charakteru szeregu,
 - dekompozycję szeregu:
 - wybór rodzaju sieci neuronowej,
 - dobór zmiennych wejściowych,
 - określenie struktury sieci neuronowej,
 - preprocessing składowych szeregu,
 - konstrukcja modelu,
 - ocena poprawności modelu,
 - porównanie z danymi rzeczywistymi,
 - obliczenie błędów predykcji,
 - analiza reszt modelu.

Preprocessing danych szeregu obejmuje badanie poprawności danych. Najbardziej skutecznym sposobem na sprawdzenie poprawności danych jest porównanie informacji pochodzącej z kilku niezależnych źródeł. W analizowanym przypadku dotyczącym pracochłonności napraw statków powietrznych wykorzystanie alternatywnego źródła informacji nie jest możliwe. Operacjonalizacja danych ma na celu wyeksponowanie pewnych charakterystyk badanych zmiennych oraz nadanie szeregom wartości zmiennych pożądanych własności. Wpływa to na szacowanie i późniejsze wykorzystanie modelu. W wyniku operacjonalizacji można uzyskać:

- szereg różnic, służący do wyeliminowania trendu,
- szereg wartości $-1, 0, +1$, pozwalający na uwypuklenie kierunku zmian wartości,
- logarytmy naturalne z wartości szeregu czasowego, mające na celu redukcję asymetrii,
- pierwiastki kwadratowe lub sześciennie z wartości szeregu, redukujące asymetrię,
- współczynniki udziału okresów, wyrażane jako iloraz wartości szeregu w danym okresie i sumy wartości obliczonej dla wszystkich okresów, itp.

Wstępne określenie charakteru szeregu ma na celu stwierdzenie, czy pomiędzy zestawem danych wejściowych oraz wartością wyjściową istnieje zależność, czy też związek pomiędzy tymi wartościami ma charakter przypadkowy. Można tego dokonać za pomocą analizy widmowej Fouriera lub wykorzystać to tego współczynniki autokorelacji. Potrzebę przeprowadzenia dekompozycji szeregu sygnalizowano już w podrozdziale 3.5.1. Jednak najważniejszą częścią konstrukcji SSN jest wybór rodzaju sieci. W prognozowaniu szeregów czasowych najczęściej wykorzystuje się SSN: MLP, RBF oraz GRNN, przedstawione w niniejszym podrozdziale. Następnie należy wybrać rząd procesu, czyli dobór zmiennych wejściowych. Jest to liczba przeszłych wartości, które są uwzględniane na wejściach sieci. Zadaniem prognosty jest określenia struktury modelu w zależności od rodzaju sieci. W sieciach MLP prognosta ustala liczbę warstw oraz liczbę elementów w

warstwach. W przypadku sieci RBF i GRNN nieodzwonne jest ustalenie liczby neuronów w warstwach ukrytych. Obecnie dostępne jest różnorodne oprogramowanie umożliwiające automatyczne określenie parametrów sieci, np. Statistica Neural Network.

Ostatnim elementem algorytmu prognozowania jest ocena poprawności modelu. Można do tego wykorzystać obliczone błędy prognoz porównując prognozy z danymi rzeczywistymi. Błędy prognoz można obliczyć według wzorów 3.80 – 3.92.

5.2. Prognozy pracochłonności napraw przy wykorzystaniu SSN

Pierwszym etapem prognozowania jest dobór sieci neuronowej, jej konfiguracja, czyli preprocessing i postprocessing, określenie liczby warstw wraz z liczbą neuronów w warstwach i dobór cech. Dobór cech ma za zadanie określenie zmiennych mających stanowić wejście sieci. Większość z tych elementów może być zrealizowana automatycznie przy wykorzystaniu programu Statistica Neural Network. Zadaniem prognosty jest podanie liczby danych wejściowych do procesu poszukiwania najlepszej sieci. Mianem najlepszej sieci określa się zwykle sieć o najmniejszym błędzie walidacyjnym lub błędzie uczącym. Przed poszukiwaniem najlepszej sieci istnieje możliwość podania okresu dla badanych danych. Jak wspomniano w poprzednim podrozdziale w przypadku tak małej ilości danych (110) niecelowy jest podział szeregu na trzy podzbiory. Program Statistica Neural Network automatycznie konfiguruje SSN w zależności od typu zgromadzonych danych. Do budowy sieci wykorzystane zostaną te same dane, jak w przypadku wyrównywania wykładniczego i metodologii ARIMA, czyli całkowita pracochłonność napraw (zmienna Pracochłonność) i pracochłonność napraw płatowców (zmienna Płatowiec).

Wyniki poszukiwania najlepszych sieci RBF odnośnie pracochłonności napraw (SP) przedstawiono w tabeli 5.1. Złożoność sieci została określona automatycznie przez program. Przetestowano 24 sieci RBF, 10 najlepszych zachowano. Efektywność najlepszej znalezionej sieci 10 jest znakomita - współczynnik regresji 0.000000, korelacja 1.000000, błąd 0.000000.

Tabela 5.1: Wyniki automatycznego poszukiwania architektury sieci RBF w przypadku zmiennej Pracochłonność.

Indeks sieci	Wejścia	Ukryte	Wyjścia	Wartość funkcji błędu	Jakość uczenia
1	1	83	1	94,76686	0,4207855
2	1	88	1	77,46116	0,3439445
3	1	92	1	61,23964	0,2719174
4	1	95	1	44,54947	0,1978094
5	1	96	1	23,10665	0,1025986
6	1	97	1	21,19566	0,0941100
7	1	98	1	17,17351	0,0762500
8	1	99	1	8,616735	0,0382600
9	1	100	1	3,573e ⁻¹²	8,19e ⁻¹⁵
10*	1	101	1	1,082e⁻¹²	4,652e⁻¹⁵


Po skonstruowaniu sieci można przystąpić do etapu nauki. Przed rozpoczęciem procesu uczenia konieczne jest wyjaśnienie parametrów uczenia. Należą do nich: liczba epok, współczynnik uczenia, bezwładność, walidacja, mieszanie przypadków.

Liczba epok określa czas trwania procesu uczenia sieci. W trakcie każdej epoki cały zbiór uczący prezentowany jest sieci, a uzyskane rezultaty stanowią podstawę do modyfikacji wag i wartości progowych neuronów. Natomiast współczynnik uczenia wpływa na tempo zmian wag dokonywanych przez algorytm. Większa wartość współczynnika uczenia może prowadzić do szybszej zbieżności algorytmu uczenia, pod warunkiem, że powierzchnia błędu nie jest zbyt skomplikowana, nie występują gwałtowne zmiany jej kształtu. Mniejsza wartość jest wskazana z punktu widzenia stabilniejszego i dokładniejszego przebiegu procesu uczenia. Dodanie członu „bezwładnościowego” powoduje, że algorytm wstecznej propagacji błędów stabilniej pokonuje drobne nierówności na powierzchni błędów, a także „nabiera prędkości” w przypadku, gdy w trakcie pewnej liczby kroków dokonywane są zmiany wag stale w tym samym kierunku. Wartość współczynnika bezwładności musi należeć do przedziału $[0.0, 1.0)$. Przed uczeniem sieci istnieje możliwość włączenia mechanizmu sprawdzania jakości procesu uczenia w oparciu o oddzielny zbiór walidacyjny. W takim przypadku jakość sieci jest dodatkowo testowana w każdej epoce w oparciu o zbiór walidacyjny. Natomiast na skuteczność procesu uczenia sieci ma wpływ mieszanie przypadków. Przy wyłączonym mechanizmie mieszania przypadków czasami mogą się pojawić problemy z uczeniem, których przyczyn należy szukać w tym, że w pierwszej fazie uczenia algorytm uczy się początkowych przypadków, a następnie – ucząc się kolejnych przypadków – „traci” wcześniej zdobytą wiedzę. Mieszanie przypadków w każdej kolejnej epoce może przeciwdziałać temu zjawisku.

Do uczenia uzyskanych SSN metodą wstecznej propagacji błędów, wartości poszczególnych parametrów zostały dobrane według literatury poświęconej uczeniu sieci neuronowych:

- czas trwania procesu uczenia – 500 000 epok,
- współczynnik uczenia – 0,001,
- bezwładność – 0,003,
- szum – 0,00,
- walidacja – tak,
- mieszanie przypadków – tak.

Schemat 10. sieci przedstawiono na rys. 5.4.



Rys. 5.4: Schemat sieci RBF w przypadku zmiennej Pracochłonność.

Sieć o radialnej funkcji bazowej RBF uczono w przypadku następujących parametrów:

- odchylenie (miary rozrzutu) – 0,51,
- sąsiedzi – 1.


Poprzez wybór liczby sąsiadów dokonano przypisania do neuronów radialnych środków skupień. Wyboru odchyleń i sąsiadów można dokonać automatycznie za pomocą techniki bez nadzoru, przy użyciu jedynie zmiennych wejściowych uczącego podzbioru danych. Mianowicie, chodzi tu o znalezienie centrów które leżałyby w środkach skupień danych uczących i miałyby odchylenia odpowiadające gęstości danych.

Wyniki statystyk wyznaczonych na podstawie zbioru uczącego przedstawiono w tabeli 5.2 a wyniki prognozy dla zmiennej Pracochłonność na rys. 5.5

Tabela 5.2: Wyniki uczenia sieci RBF.

Średnia	333,4257
Odchylenie standardowe	226,3374
Średni błąd bezwzględny	$4,152e^{-13}$
Iloraz odchyień standardowych	$2,228e^{-15}$
Korelacja	1

Średnia wartość zmiennej wyjściowej oraz odchylenie standardowe obliczone zostały na podstawie zadanych wartości tej zmiennej, zgromadzonych w zbiorze uczącym (110 obserwacji). Średni błąd bezwzględny jest różnicą pomiędzy wartością zadaną i wartością uzyskaną na wyjściu dla zmiennej wyjściowej.




Rys. 5.5: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku sieci neuronowej.

Głównym wskaźnikiem jakości zbudowanego przez sieć modelu regresyjnego jest iloraz odchyłeń standardowych. Standardowy współczynnik korelacji R Pearsona dla wartości zadanej i wartości uzyskanej na wyjściu wyniósł 1. Orientacyjnie przyjmuje się, że iloraz równy 0.1 (lub mniej) świadczy o dobrej realizacji regresji przez sieć, zaś iloraz powyżej 0.7 (lub więcej) dyskwalifikuje stworzony przez sieć model.


Wyniki błędów prognozy w porównaniu z danymi rzeczywistymi przedstawiono w tabeli 5.3, natomiast wykres błędu uczenia na rys 5.6.

Tabela 5.3: Wyniki błędów prognozy w przypadku sieci RBF oraz zmiennej Pracochłonność.

Wartość						
SSE	MSE	MAPE	U_1	U_2	U_3	I^2
2520432	210036	24,75%	8,3%	11,7%	80,0%	0,7548



Rys. 5.6: Zmiana wartości błędu w trakcie uczenia sieci RBF.



Rys. 5.7: Wykres rozkładu wag sieci RBF.

Uzyskany błąd prognozy MAPE wynoszący 24,75% jest porównywalny z błędami prognoz uzyskiwanymi przy wykorzystaniu metody wyrównywania wykładniczego i metody ARIMA. Na rys 5.7 przedstawiono wykres rozkładu wag badanej sieci. Obrazuje on rozkład wag w przedziale $[-3,5; +3,5]$, z krokiem równym 0,25. Rozkład znormalizowany został w taki sposób, że słupek odpowiadający najliczniejszemu przedziałowi ma wysokość równą 1,0, pozostałe słupki są odpowiednio niższe. Gdyby sieć była źle nauczona lub nauczona nie całkowicie, wystąpiłby wtedy równomierny rozkład wartości wag. Natomiast sieci dobrze nauczonej odpowiadają wykresy słupkowe wskazujące na wyraźną dywersyfikację wartości wag (wykresy wielomodalne).

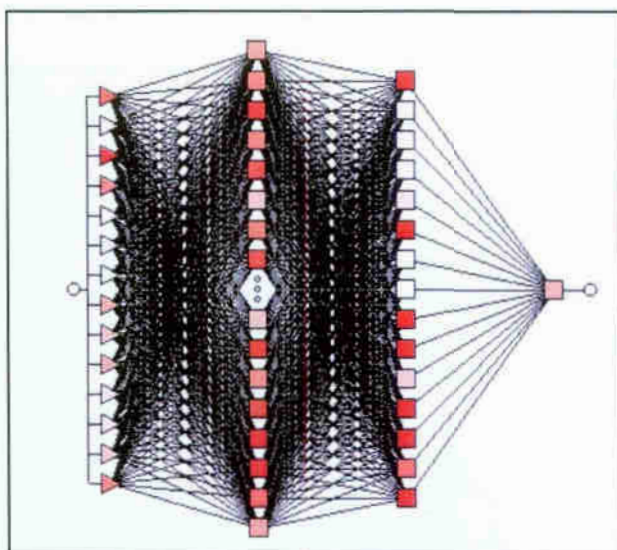
W celu porównania wyników prognozy uzyskanych za pomocą sieci RBF z innymi metodami rozpoczęto poszukiwanie najlepszej 3 (4) warstwowej sieci MLP. Architektura sieci MLP (złożoność sieci) została określona automatycznie. Uzyskano 10 najlepszych sieci, których parametry przedstawiono w tabeli 5.4. Architekturę najlepszej zaprezentowano na rys 5.8. W celu uzyskania bardziej dokładnych wyników, uzyskane parametry, czyli ilość neuronów w warstwach najlepszej sieci wprowadzono jako parametry poszukiwania sieci i przystąpiono do ponownego poszukiwania, bardziej dokładnego. Wyniki zestawiono w tabeli 5.5.

Tabela 5.4: Wyniki poszukiwania architektury sieci MLP w przypadku zmiennej Pracochłonność.

Indeks sieci	Wejścia	Ukryte	Ukryte (2)	Błąd uczenia	Jakość uczenia
1	1	20	-	1,908956	0,009174
2	1	14	-	1,829226	0,008770
3	1	19	-	1,766687	0,008483
4	1	17	-	1,608525	0,007735
5	1	16	11	1,452209	0,006720
6	1	16	13	1,449826	0,006973
7	1	16	10	1,426424	0,006857
8	1	25	15	1,363950	0,006455
9	1	25	12	1,269666	0,006088
10*	1	38	15	0,97415	0,004421

Tabela 5.5: Wyniki poszukiwania sieci MLP w przypadku zmiennej Pracochłonność.

Indeks sieci	Wejścia	Ukryte	Ukryte (2)	Błąd uczenia	Jakość uczenia
1	1	38	15	1,216317	0,005513
2	1	38	15	1,194852	0,005412
3	1	38	15	1,186940	0,005385
4	1	38	15	1,166862	0,005289
5	1	38	15	1,166036	0,005294
6	1	38	15	1,126829	0,005117
7	1	38	15	1,122013	0,005095
8	1	38	15	1,058951	0,004806
9	1	38	15	0,981409	0,004444
10*	1	38	15	0,974147	0,004421



Rys. 5.8: Schemat sieci MLP w przypadku zmiennej Pracochłonność oraz danych z 9 lat.


Po przeprowadzeniu szeregu poszukiwań uzyskano „najlepszą” sieć MLP – warstwową (sieć nr 10* zaznaczona w tabeli 5.5), a jej architekturę zilustrowano na rys 5.8. Do uczenia sieci zastosowano algorytm wstecznej propagacji błędów. Zastosowano parametry uczenia jak w poprzednim przypadku, a proces uczenia zilustrowano w tab. 5.6 oraz na rys 5.9. Pomimo zastosowania różnych algorytmów uczenia takich jak: metoda gradientów sprzężonych, Quasi - Newtona nie osiągnięto mniejszego błędu prognozy niż przy zastosowaniu sieci RBF (tab. 5.7). Wyniki prognozy przedstawiono na rys 5.10.

Tabela 5.6: Wyniki uczenia sieci MLP.


Średnia	335,7500
Odchylenie standardowe	221,3421
Średni błąd bezwzględny	0,56404
Iloraz odchyłeń standardowych	0,00393
Korelacja	0,99999

Tabela 5.7: Wyniki błędów prognozy SSN - MLP w przypadku zmiennej Pracochłonność.


Wartość						
SSE	MSE	MAPE	U ₁	U ₂	U ₃	I ²
2771545	230962	30,91%	8,33%	1,79%	89,88%	0,8299



Rys. 5.9: Zmiana wartości błędów w trakcie uczenia sieci MLP.



Rys. 5.10: Wykresy prognoz dla zmiennej Pracochłonność w przypadku SSN – MLP.



Rys. 5.11: Wykres rozkładu wag sieci MLP.

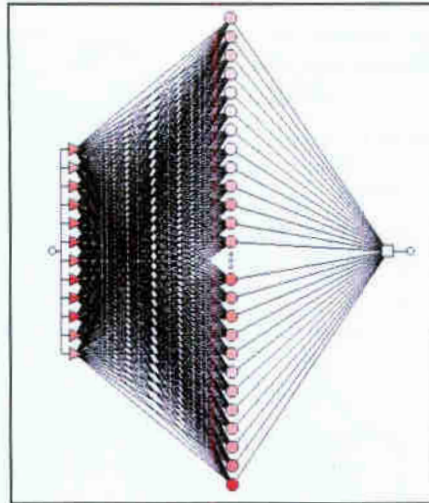
W celu porównania rezultatów uzyskanych za pomocą SSN z wynikami dotyczącymi prognoz przy wykorzystaniu metod wyrównywania wykładniczego oraz metody ARIMA przeprowadzono predykcję pracochłonności napraw podzespołów płatowca przy wykorzystaniu SSN. Algorytm postępowania jest identyczny jak w przypadku wszystkich awarii statków powietrznych. Wyniki poszukiwania najlepszej sieci RBF po dokładnym poszukiwaniu przedstawiono w tabeli 5.8.

Tabela 5.8: Wyniki poszukiwania sieci RBF w przypadku zmiennej Płatowiec.

Indeks sieci	Wejścia	Ukryte	Wyjścia	Błąd uczenia	Jakość uczenia
1	1	95	1	3,00558	0,05367
2	1	96	1	2,14406	0,03829
3	1	97	1	9,180e ⁻¹³	1,020e ⁻¹⁴
4	1	98	1	3,809e ⁻¹²	6,186e ⁻¹⁴
5	1	98	1	1,780e ⁻¹²	3,019e ⁻¹⁴
6	1	98	1	1,594e ⁻¹²	1,269e ⁻¹⁴
7	1	98	1	7,231e ⁻¹²	1,246e ⁻¹⁴
8	1	98	1	9,180e ⁻¹³	1,020e ⁻¹⁴
9	1	98	1	6,031e ⁻¹³	9,823e ⁻¹⁵
10*	1	98	1	4,349e⁻¹³	7,749e⁻¹⁵

Schemat architektury sieci 10* przedstawiono na rys 5.12. Sieć uczono algorytmem wstecznej propagacji błędów o parametrach:

- czas trwania procesu uczenia – 500 000 epok,
- współczynnik uczenia – 0,001,
- bezwładność – 0,003,
- szum – 0,00,
- walidacja – tak,
- mieszanie przypadków – tak.




Rys. 5.12: Schemat sieci RBF w przypadku zmiennej Płatowiec oraz danych z 9 lat.

Tabela 5.9: Wyniki uczenia sieci RBF.

Średnia	116,5918
Odchylenie standardowe	56,28899
Średni błąd bezwzględny	$1,431e^{-12}$
Iloraz odchyżeń standardowych	$1,269e^{-14}$
Korelacja	1


Wykres błędu uczenia sieci RBF przedstawiono na rys 5.13, na którym liczba epok wynosi tylko 1500, w celu bardziej przejrzystego przedstawienia spadku błędu uczenia SSN.




Rys. 5.13: Zmiana wartości błędów w trakcie uczenia sieci RBF.

Tabela 5.10: Wyniki błędów prognozy SSN - RBF w przypadku zmiennej Płatowiec.

Wartość						
SSE	MSE	MAPE	U_1	U_2	U_3	I^2
4908	409	14,02%	8,3%	0,1%	91,6%	0,0185



Rys. 5.14: Wykresy prognoz dla zmiennej Płatowiec w przypadku SSN – RBF w 2000 r.




Rys. 5.15: Wykres rozkładu wag sieci RBF w przypadku zmiennej Płatowiec.

W celu porównania wyników prognozy uzyskanych za pomocą sieci RBF rozpoczęte zostanie poszukiwanie najlepszej 3 (4) warstwowej sieci MLP. Architektura sieci MLP, jej złożoność zostanie określona automatycznie. Po dokładnym poszukiwaniu uzyskano 10 najlepszych sieci, które przedstawiono w tabeli 5.11.

Tabela 5.11: Wyniki poszukiwania sieci MLP w przypadku zmiennej Płatowiec.

Indeks sieci	Ilość warstw	Wejścia	Ukryte	Ukryte (2)	Błąd uczenia	Jakość uczenia
1	4	1	16	11	0,2648210	0,00472
2	4	1	25	6	0,2435807	0,00434
3	4	1	38	12	0,2418224	0,00432
4	4	1	38	12	0,2407333	0,00430
5	4	1	38	12	0,2390406	0,00426
6	4	1	38	12	0,2356758	0,00421
7	4	1	38	12	0,2356361	0,00421
8	4	1	38	12	0,2180889	0,00389
9	4	1	38	12	0,1775434	0,00317
10*	4	1	38	12	0,1596811	0,00285

Schemat architektury 10* – tej sieci przedstawiono na rys 5.16. Sieć 10* MLP ma budowę 4 warstwową.




Rys. 5.16: Schemat sieci MLP w przypadku zmiennej Płatowiec oraz danych z 9 lat.

Do uczenia ww. sieci zastosowano algorytm wstecznej propagacji błędów. Następnie douczano sieć metodami: gradientami sprzężonymi oraz metodą Quasi – Newtona przy liczbie epok 10000. Charakterystykę statystyk regresyjnych przedstawiono w tabeli 5.12.


Tabela 5.12: Wyniki uczenia sieci MLP.

Średnia	116,5918
Odchylenie standardowe	56,28899
Średni błąd bezwzględny	0,0002396
Iloraz odchyłeń standardowych	$5,737e^{-06}$
Korelacja	1

Wykres błędu uczenia sieci MLP przedstawiono na rys 5.17, na którym liczba epok wynosi tylko 20000. W celu bardziej przejrzystego przedstawienia spadku błędu uczenia SSN zaprezentowano na wykresie co 25 iterację.




Rys. 5.17: Zmiana wartości błędu w trakcie uczenia sieci MLP.



Rys. 5.18: Prognoza dla zmiennej Płatowiec w 2000 roku w przypadku SSN – MLP.

Tabela 5.13: Wyniki błędów prognozy SSN - MLP w przypadku zmiennej Płatowiec.

Wartość						
SSE	MSE	MAPE	U ₁	U ₂	U ₃	I ²
16904	1409	15,10%	8,3%	2,8%	88,9%	0,0639




Rys. 5.19: Wykres rozkładu wag sieci MLP w przypadku zmiennej Płatowiec.

Powyzsze wyniki prognozy swiadcza o tym, ze przy pomocy sieci o architekturze RBF mozna uzyskac mniejsze bledy prognoz niz przy wykorzystaniu sieci MLP.

5.3. Wnioski


Uzyskane wyniki prognoz wskazuja, ze istnieje mozliwosc wykorzystania SSN do prognozowania pracochlonnosci napraw statkow powietrznych. Jednak przy braku zmiennych zaleznych jak np. nalot statkow powietrznych w danym miesiacu, brak jest mozliwosci uzyskania modeli o lepszych charakterystykach i wiekszej dokladnosci.

Ze wzgledu na zbyt mala ilosc danych do budowy SSN niecelowy byl ich podzial na zbior testowy i zbior walidacyjny. Do budowy zbioru uczacego SSN wykorzystano wszystkie dostepne dane (z 9 - ciu lat). Porownujac wyniki prognoz z pracą [Rej2002] uzyskane przez autorkę błędy rzędu 37-38% przy wykorzystaniu SSN, a dotyczące bezrobocia przy modelach bez zmiennej opisującej są podobne do uzyskanych w niniejszej rozprawie. Na rys 5.20 przedstawiono prognozy napraw samolotów przy wykorzystaniu różnych metod predykcji.



Rys. 5.20: Porównanie prognoz dla zmiennej Pracochłonność w 2000 roku przy wykorzystaniu różnych metod prognozowania.

Najmniejsze błędy, czyli najbardziej trafne prognozy uzyskano w przypadku modeli ARIMA oraz SSN – RBF. Z kolei w przypadku predykcji pracochłonności napraw płatowca (rys 5.21) błędy uzyskanych prognoz wyniosły (6-7%), przy metodzie wyrównywania wykładniczego i metodzie ARIMA, natomiast przy zastosowaniu SSN najmniejsze błędy wyniosły 14-15%.



Rys. 5.21: Porównanie prognoz dla zmiennej Płatowiec w 2000 roku przy wykorzystaniu różnych metod prognozowania.

ROZDZIAŁ 6

ZAKOŃCZENIE

6.1. Podsumowanie

W tezie niniejszej rozprawy wskazano, że „istnieją modele prognostyczne, które z określoną dokładnością są w stanie przewidzieć przyszłe wielkości pracochłonności usuwania awarii na podstawie zgromadzonych danych” oraz sformułowano pytanie, czy na podstawie uzyskanych wyników prognoz, istnieje możliwość identyfikacji stanu technicznego eksploatowanych statków powietrznych. W celu udowodnienia postawionej tezy konieczne było opracowanie modeli prognostycznych opisujących pracochłonność napraw statków powietrznych.

Pierwszy etap pracy polegał na zgromadzeniu danych statystycznych. Następnie dokonano dekompozycji statków powietrznych na układy i podzespoły, ze względu na rodzaj występujących awarii. Było to związane z tym, że inne rodzaje awarii wystąpiły np. w podwoziach statku powietrznego, natomiast inne w instalacji elektrycznej samolotu. Największą częstotliwość występowania awarii zaobserwowano w przypadku elementów silnika. W wyniku analizy stwierdzono, że pracochłonność napraw silnika stanowiła 53,11% całkowitej pracochłonności napraw, przyjętej za 100%. Pracochłonność napraw płatowca wyniosła 34,40% i odpowiednio w przypadku URE – 7,21% i osprzętu – 5,27%.

Drugi etap pracy polegał na podzieleniu pracochłonności napraw poszczególnych podzespołów według przyjętego podziału statku powietrznego. Problemem, który pojawił się była zbyt duża liczba dni, w których nie dokonywano napraw (SP). W celu rozwiązania powyższego problemu dokonano agregacji danych na okresy tygodniowe, dwutygodniowe, i miesięczne. W przypadku danych dotyczących napraw osprzętu, URE oraz silnika liczba dni, w których nie wykonywano naprawy dyskwalifikowała zmienną do prognozowania i dlatego zrezygnowano z prognozowania pracochłonności napraw powyższych podukładów.

Trzeci etap pracy polegał na opracowaniu własnego algorytmu prognozowania przy wykorzystaniu modeli wyrównywania wykładniczego i modeli ARIMA do posiadanych danych. Następnie dokonano dekompozycji szeregów, co uwypukliło charakterystyczne zależności. Przeprowadzona dekompozycja szeregu wskazała na to, że najmniejsze wartości pracochłonności usuwania awarii zanotowano w okresach grudzień – marzec. Przyczyną jest zmniejszenie intensywności wykonywania lotów w okresach zimowych. Przyczyną pośrednią było pogorszenie warunków atmosferycznych uniemożliwiających bezpieczne wykonywanie lotów. Najwięcej czasu na usuwanie awarii poświęcono w okresach letnich, które charakteryzują się zdecydowanie lepszymi warunkami atmosferycznymi do wykonywania lotów.

Na podstawie algorytmu dokonano predykcji pracochłonności napraw całego statku powietrznego i napraw płatowca, porównano uzyskane wyniki z wartościami rzeczywistymi i obliczono błędy prognoz. Uzyskane błędy prognozy przy wykorzystaniu metody wyrównywania wykładniczego i metody ARIMA w przypadku pracochłonności napraw całego statku powietrznego wyniosły 24-25%, natomiast w przypadku płatowca - 6-7%. Świadczy to o konieczności dekompozycji statku powietrznego na podzespoły.

W końcowym etapie pracy rozpatrywano możliwość zastosowania sztucznych sieci neuronowych do prognozowania pracochłonności napraw. Z uwagi na brak dodatkowych zmiennych objaśniających, osiągnięte błędy prognoz są na poziomie 24-25% dla pracochłonności napraw (SP) w 2000r. Dekompozycja statku powietrznego na układy pozwoliła na zmniejszenie błędów prognozy do 13-14% w przypadku pracochłonności napraw płatowców. Uzyskane i przedłożone w niniejszej pracy rezultaty oraz wnioski uzasadniają celowość dalszych badań.

6.2. Perspektywy dalszych badań

Przedstawiony w niniejszej pracy algorytm prognozowania pracochłonności napraw statków powietrznych, może być z powodzeniem zastosowany w ośrodkach eksploatujących statki powietrzne. Po dokonaniu niewielkiego przekształcenia można go wykorzystać do prognozowania zużycia ilości paliwa. Koniecznym narzędziem do wspomagania prognoz czasochłonności napraw lub możliwości wystąpienia awarii jest system ekspertowy zawierający bazę danych o awariach oraz o aktualnym miejscu (SP) w przestrzeni stanów. Ponadto, wskazane byłoby zbudowanie systemu ekspertowego objaśniającego kolejność wykonywania czynności w celu naprawy (SP). Połączenie obydwu zbudowanych systemów ekspertowych z analizowanymi w niniejszej pracy modelami SSN umożliwi realne określenie stanu technicznego eksploatowanych (SP).

Niektóre z przedstawionych w pracy idei wymagają dalszych badań, jednak przeprowadzona analiza pod kątem ich praktycznego zastosowania pozwala sformułować interesujące wnioski. Autor proponuje obsługę statków powietrznych według stanu technicznego, nawet w przypadku eksploatowanych samolotów według resursu. Oczywiście wymagane jest zgromadzenie odpowiednich danych, dotyczących awarii oraz dokładna analiza rodzaju wykonywanych lotów. W celu uzyskania dokładniejszych prognoz należy:

- wprowadzić większą liczbę statków powietrznych do badań, co umożliwi zwiększenie przypadków awarii, oraz zmniejszenie dni, miesięcy w których nie dokonywano napraw,
- wprowadzić dodatkowe zmienne objaśniające, przedstawione w rozdziale czwartym,
- zwiększyć liczbę danych wprowadzanych do prognozowania.

Konieczne wydaje się wprowadzenie systemów ekspertowych do wspomagania podejmowania decyzji dotyczących awarii, ich przyczyn i mogących wystąpić skutków. Ciągła kontrola stanu technicznego jest możliwa jedynie po wprowadzeniu do użytkowania (SP) nowszej generacji wyposażonych w rejestratory parametrów pracy urządzeń. Celowa wydaje się analiza i odpowiedź na postawione pytanie: Czy warto eksploatować przestarzały sprzęt lotniczy, czy lepiej dokonać zakupu nowszego, oszczędniejszego i mniej podatnego na awarie statku powietrznego?

LITERATURA

- [Acz2000] Aczel A., *Statystyka w zarządzaniu*, Wydawnictwo Naukowe PWN, Warszawa 2000.
- [Bar1994] Baraniecki J., *Najważniejsze problemy techniczne i eksploatacyjne – ich wpływ na bezpieczeństwo lotów*, Przegląd WLOP nr 3/1994, Poznań 1994.
- [Bia2000] Biało M., *Podstawowe właściwości sieci neuronowych i hybrydowych systemów ekspertowych*, Wydawnictwa Uczelniane Politechniki Koszalińskiej, Koszalin 2000.
- [Bła2003] Błaszczak J., *Walory techniczno – bojowe samolotów wielozadaniowych F-16C, JAS 39 Gripen, Mirage 2000-5 a jakość samolotów bojowych WLOP*, Przegląd WLOP nr 3/2003, Poznań 2003.
- [Bob1999] Bobrowski D., *Rozkłady prawdopodobieństwa ciągu zależnych czasów pomiędzy odnowami*, Zagadnienia Eksploatacji Maszyn, Zeszyt 3 (119), strony 429 – 432, 1999.
- [Box1983] Box G.E.P., Jenkins G.M., *Analiza szeregów czasowych – Prognozowanie i sterowanie*, Państwowe Wydawnictwa Naukowe, Warszawa 1983.
- [Chr1995] Chromiec J., Strzemieczna E., *Sztuczna Inteligencja – Metody konstrukcji i analizy systemów eksperckich*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1995.
- [Cie2001] Cieślak M., *Prognozowanie gospodarcze – Metody i zastosowanie*, Wydawnictwo Naukowe PWN, Warszawa 2001.
- [Cyu2000] Cyulin W., Lemski J., *Modele trwałości urządzeń technicznych*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (124), strony 53 – 67, 2000.
- [Cza2001] Czajgucki J.Z., *Synteza teorii niezawodności a rozwiązywanie problemów zawodności obiektów technicznych*, Zagadnienia Eksploatacji Maszyn, Zeszyt 1 (125), strony 45 – 58, 2001.
- [Cze1980] Czerwiński Z., Guzik B. *Prognozowanie ekonometryczne*, PWE, Warszawa 1980.
- [Dan1982/1] Danilecki S., *Zastosowanie analizy trwałości zmęczeniowej do oceny skutków uszkodzeń lokalnych i efektów napraw powłok skrzydeł, Cz. I. Kryterium oceny skutków uszkodzeń i efektów napraw*, Technika Lotnicza i Astronautyczna, Miesięcznik Sekcji Lotniczej Stowarzyszenia Inżynierów i Techników Mechaników Polskich, Nr 4/1982.
- [Dan1995] Danilecki S., *Kształtowanie systemu logistyki statków powietrznych z elementami probabilistycznej oceny bezpieczeństwa ich struktury*, Prace naukowe Politechniki Warszawskiej, Zeszyt 162, Warszawa 1995.
- [Dan1999] Danilecki S., *Ocena niezawodności statku powietrznego*, Zagadnienia Eksploatacji Maszyn, Zeszyt 3 (119), strony 445 – 452, 1999.
- [Dan2001] Danilecki S., *Eksploatowanie samolotów*, Ośrodek Wydawniczo – Poligraficzny SIMP, Warszawa 2001.
- [Dąb2000/1] Dąbrowski T.M., *Uogólnione, niezawodnościowe miary eksploatacyjnych właściwości systemu antropotechnicznego*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (124), strony 69 – 84, 2000.

- [Dąb2000/2] Dąbrowski T.M., *Efekt i potencjał jako właściwości systemu antropotechnicznego. Część I*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (124), strony 121 – 137, 2000.
- [Dąb2001] Dąbrowski T.M., *Efekt i potencjał jako właściwości systemu antropotechnicznego. Część II*, Zagadnienia Eksploatacji Maszyn, Zeszyt 1 (125), strony 211 – 234, 2001.
- [Dąb2002/1] Dąbrowski T.M., *Diagnostyczne wnioskowanie użytkowe w oparciu o charakterystyki potencjalowo – efektowe*, Zagadnienia Eksploatacji Maszyn, Zeszyt 1 (129), strony 183 – 195, 2002.
- [Dąb2002/2] Dąbrowski T.M., *Diagnostyczne wnioskowanie użytkowe - obsługowe w oparciu o charakterystyki potencjalowe*, Zagadnienia Eksploatacji Maszyn, Zeszyt 2 (130), strony 171 – 183, 2002.
- [Dit2000/1] Dittman P., *Metody prognozowania sprzedaży w przedsiębiorstwie*, Wydawnictwa Akademii Ekonomicznej im. Oskara Langego we Wrocławiu, Wrocław 2000.
- [Dit2000/2] Dittman P., *Prognozowanie w przedsiębiorstwie*, Wydawnictwo Statsoft Polska, Kraków 2000.
- [Dwi1991] Dwiliński L. *Wstęp do teorii eksploatacji obiektu technicznego*, Wydawnictwa Politechniki Warszawskiej, Warszawa 1991.
- [Fig1996] Figurski J., Wieciński W. *Modelowanie systemu eksploatacji*, Wydawnictwo Bellona, Warszawa 1996.
- [Fli1999] Flight International, *F-16 – Prawa metryki, czyli zmęczenie materiału*, Defense Week 7-13.06.1999.
- [Gło2001] Głowiński S., Krzyżyński T. *Zastosowanie systemu ekspertowego do diagnostyki samolotów*, VIII Warsztaty Naukowe PTSK, 30 sierpnia – 1 września, 2001, Gdańsk-Sobieszewo, pp.149-153, ISBN 83-87359-49-1.
- [God1998] Godzimirski J., „Naprawa Płatowców”, Wydawnictwo Wojskowej Akademii Technicznej, Warszawa 1998.
- [Hal2003] Halbiniak Z., Hudyma E., Józwiak I.J., *Niezawodność predykcji szeregów czasowych z chaosem deterministycznym algorytmem liniowej aproksymacji*, Zagadnienia Eksploatacji Maszyn, Zeszyt 1 (133), strony 47 – 59, 2003.
- [Han1989] Hanke J., Reitsch A., *Business Forecasting*, Library of Congress, Massachusetts 1989.
- [Jaź1989] Jaźwiński j., Borgoń J., *Niezawodność eksploatacyjne i bezpieczeństwo lotów*, Wydawnictwo komunikacji i Łączności, Warszawa 1989.
- [Kam1997] Kamiński J., *Eksploatacja samolotów i śmigłowców, Cz II*, Wydawnictwo Wojskowej Akademii Technicznej, Warszawa 1997.
- [Kam1998] Kamiński J., *Eksploatacja samolotów i śmigłowców, Cz I*, Wydawnictwo Wojskowej Akademii Technicznej, Warszawa 1998.
- [Kap2000] Kapłon K., *Metoda szacowania miar niezawodności systemów „sprzęt – operator” z wykorzystaniem sieci Petriego*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (124), strony 85 – 98, 2000.
- [Kas1994] Kaszyński W., Kaniewski Z., *Zabezpieczenie inżynierijno – lotnicze*, Wydawnictwo Wojskowej Akademii Technicznej, Warszawa 1994.
- [Kli1998] Klimaszewski S., *Prognozowanie wybranych wskaźników niezawodności związanych z uszkodzeniami struktury nośnej samolotu myśliwskiego*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (116), strony 595 – 605, 1998.

[Kno2002] Knopik L., Landowski B., Perczyński D., *Prognozowanie stanu systemu eksploatacji transformatorów rozdzielczych na podstawie badań modelowych*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (132), strony 163 – 175, 2002.

[Kno2003] Knopik L., *Maksymalizacja zysku w diagnostycznym systemie eksploatacji pojazdów z wykorzystaniem procesów semi – Markowa*, Zagadnienia Eksploatacji Maszyn, Zeszyt 1 (133), strony 153 – 168, 2003.

[Kon1975] Konieczny J., *Podstawy eksploatacji urządzeń*, Wydawnictwo MON, Warszawa 1975.

[Kop2002] Kopczewski M., Skrzypniak R., *Prognozowanie szeregów czasowych metodą wyrównywania wykładniczego z wykorzystaniem programu Excell – materiał studyjno – projektowy*, Wydział Elektroniki Politechniki Koszalińskiej, Koszalin 2002.

[Kor1994] Korbicz J., Obuchowski A., Uciński D., *Sztuczne sieci neuronowe – podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.

[Kow1994] Kowalkowski Z., Wiłnicki F., Tuchołka T., *System wspomaganie procesu eksploatacji samolotów oparty na zintegrowanym pokładowym systemie analizującym – sterującym*, Przegląd WLiOP nr 1, Poznań 1994.

[Kow1995] Kowalkowski Z., Błachowicz J., *ESTA as an environment for creating expert system for support SOS – 3M deck device diagnosing process*, Intelligent Information Systems IV Proceedings of Workshop held in Augustów, 5-9 June, pages 240-245, 1995.

[Kud1999] Kudelski R., Pintara J., Szczepanik R., *System diagnostyczny o cechach eksperckich do monitorowania stanu technicznego zespołu napędowego samolotu I – 22 Iryda*, IV Sympozjum Naukowe – „Problemy Techniczno – Eksploatacyjne w kształceniu pilotów”, Wydawnictwo Wyższej Szkoły Oficerskiej Sił Powietrznych, Dęblin 1999.

[Kuk2000] Kukielka L., *Podstawy badań inżynierskich*, Wydawnictwo Uczelniane Politechniki Koszalińskiej, Koszalin 2000.

[Lem2001] Lemski J., *Modele zmian stanu technicznego urządzeń*, Zagadnienia Eksploatacji Maszyn, Zeszyt 1 (125), strony 193 – 209, 2001.

[Lew1993/1] Lewitowicz J., Borgoń J., Ząbkowicz W., *Problemy badań i eksploatacji techniki lotniczej Cz. 1*, Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 1993.

[Lew1993/2] Lewitowicz J., Borgoń J., Ząbkowicz W., *Problemy badań i eksploatacji techniki lotniczej Cz. 2*, Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 1993.

[Lew2001] Lewitowicz J., *Podstawy eksploatacji statków powietrznych Cz. 1*, Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 2001.

[Lew2003] Lewitowicz J., Kustroń K., *Podstawy eksploatacji statków powietrznych Cz. 2*, Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 2003.

[Lul2000] Lula P., *Wykorzystanie sztucznej inteligencji w prognozowaniu. Prognozowanie w przedsiębiorstwie*, Wydawnictwo Statsoft Polska, Kraków 2000.

[Leb2002] Lebkowski P., *Model planowania demontażu maszyn i urządzeń*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (132), strony 151 – 161, 2002.

[Mas1996] Masters T., *Sieci Neuronowe w praktyce, programowanie w C++*, Wydawnictwo Naukowo – Techniczne, Warszawa 1996.

[Mic2000] Michalik K., *Neuronix 3.0 – Symulator sztucznych sieci neuronowych – podręcznik użytkownika*, Wydawnictwo AITECH, Katowice 2000.

[Mul1996] Mulawka J.J., *Systemy ekspertowe*, Wydawnictwa Naukowo – Techniczne, Warszawa 1996.

- [Nie2000] Niederliński A., *Regułowe systemy ekspertowe*, Wydawnictwo Pracowni Komputerowej Jacka Skalmierskiego, Gliwice 2000.
- [Nor1977] Norma Wybór wskaźników niezawodności, PN-77/N-04010, PKNMiJ 1977.
- [Now1998] Nowak E., *Prognozowanie gospodarcze – metody, modele, zastosowania, przykłady*, Agencja Wydawnicza PLACET, Warszawa 1998.
- [Now2000] Nowakowski T., *Modele niepewności informacji eksploatacyjnych*, Zagadnienia Eksploatacji Maszyn, Zeszyt 2 (122), strony 143 – 150, 2000.
- [Okr1980] Okręgliński W., Łopuszyński B. *Użytkowanie urządzeń mechanicznych*, Wydawnictwa Naukowo – Techniczne, Warszawa 1980.
- [Paw1996] Pawlak M., *Systemy ekspertowe w eksploatacji maszyn*, Wydawnictwa Uczelniane Politechniki Lubelskiej, Lublin 1996.
- [Pow2001] Powierża L., *Eksploatacja, eksploatyka, eksploatologia – czyli kognitywistyka eksploatacyjna*, Zagadnienia Eksploatacji Maszyn, Zeszyt 2 (126), strony 235 – 246, 2001.
- [Rej2002] Rejer I., *Metoda modelowania wielkowymiarowego systemu z użyciem metod sztucznej inteligencji na przykładzie bezrobocia w Polsce*, Rozprawa Doktorska, Politechnika Szczecińska, Wydział Informatyki, Szczecin 2002.
- [Smo1997] Smoliński H., Tomaszek H., *Wprowadzenie do oceny niezawodności elementów konstrukcji lotniczych w warunkach zmęczenia*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (112), strony 525 – 534, 1997.
- [Sło1996] Słowiński B. *Podstawy badań i oceny niezawodności obiektów technicznych*, Wydawnictwa Uczelniane Politechniki Koszalińskiej, Koszalin 1996.
- [Sob2001] Sobczyk M., *Statystyka*, Wydawnictwo Naukowe PWN, Warszawa 2001.
- [Sta1994] STATISTICA for Windows, Volume III, STATISTICS II, StatSoft Inc. Tulsa 1984.
- [Sta2000] *Statistica Neural Networks, Wersja 4.0 F*, StatSoft Inc. Tulsa 2000.
- [Stę2002] Stepień P., *Prognozowanie ekonometryczne*, Materiały z wykładów udostępnione przez autora w formie tekstowej w 2002r.
- [Swa1999] Swatowski P., Góźdź T., *System do pogładowego przedstawienia właściwości sieci neuronowych*, Praca Dyplomowa AGH im. S.Staszica w Krakowie, Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Kraków 1999.
- [Szy1998] Szymczak J., Tomaszek H., *Zarys metody prognozy niezawodności i trwałości elementów mechanicznych silników lotniczych pracujących w warunkach zmęczenia*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (116), strony 583 – 593, 1998.
- [Tad2000] Tadeusiewicz R., Lula P., *Neuronowe metody analizy szeregów czasowych i możliwości ich zastosowań w zagadnieniach biomedycznych*, Biocybernetyka i inżynieria biomedyczna 2000 pod redakcją Nałęcza M., Tom 6, Sieci neuronowe, Rozdział 16, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
- [Tar1999] Tarełko W., *Komputerowo wspomagany system projektowania naprawialności*, Zagadnienia Eksploatacji Maszyn, Zeszyt 3 (119), strony 453 – 471, 1999.
- [Tom1999/1] Tomaszek H., Wróblewski M., *Zarys oceny efektywności eksploatacji wojskowych statków powietrznych z uwzględnieniem kosztów*, Zagadnienia Eksploatacji Maszyn, Zeszyt 3 (119), strony 433 – 443, 1999.
- [Tom1999/2] Tomaszek H., Wróblewski M., *Metoda oceny efektywności eksploatacji wojskowych statków powietrznych z uzupełnieniem strat pomiędzy operacjami*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (120), strony 677 – 687, 1999.
- [Tom2000] Tomaszek H., Wróblewski M., *Metoda oceny efektywności eksploatacji wojskowych statków powietrznych bez uzupełniania strat pomiędzy operacjami*, Zagadnienia Eksploatacji Maszyn, Zeszyt 1 (121), strony 71 – 81, 2000.

[Tom2002/1] Tomaszek H., Stępień S., *Zarys metody oceny niezawodności wybranej klasy lotniczych obiektów technicznych na podstawie informacji diagnostycznych*, Zagadnienia Eksploatacji Maszyn, Zeszyt 2 (130), strony 53 – 66, 2002.

[Tom2002/2] Tomaszek H., Wróblewski M., *Metoda oceny efektywności eksploatacji wojskowych statków powietrznych*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (132), strony 79 – 91, 2002.

[Tyl1998] Tylicki H. *Optymalizacja procesu prognozowania stanu technicznego pojazdów mechanicznych*, Wydawnictwa Uczelniane Akademii Techniczno – Rolniczej, Bydgoszcz 1998.

[Waż1990] Ważyńska – Fiok K., Jaźwiński J. *Niezawodność systemów technicznych*, Państwowe Wydawnictwa Naukowe, Warszawa 1990.

[Wel1998] Welfe A. *Ekonometria*, Państwowe Wydawnictwo Ekonomiczne, Warszawa 1998.

[Zag1996] Zagdański Z., *Stany awaryjne statków powietrznych*, Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 1996.

[Zag1997] Zagdański Z., *Stan awaryjny statku powietrznego w ujęciu probabilistycznym*, Zagadnienia Eksploatacji Maszyn, Zeszyt 4 (112), strony 559 – 569, 1997.

[Zbo2001] Zboiński M., *Badania wrażliwości wzmacniacza hydraulicznego statku powietrznego na produkty zużycia węzłów tribologicznych*, Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 2001.

[Zgó2001] Zgólkowa H., *Praktyczny Słownik Współczesnej Polszczyzny*, Tom 7, 32, 36, Wydawnictwo Kurpisz, Poznań 2001.

[Zie2000] Zieliński J. i in., *Inteligentne systemy w zarządzaniu*, Wydawnictwo Naukowe PWN, Warszawa 2000.

SPIS RYSUNKÓW

Rys. 1.1: Okresy eksploatacji urządzeń mechanicznych.	12
Rys. 1.2: Parametry urządzeń mechanicznych.	13
Rys. 1.3: Wymagania stawiane urządzeniom mechanicznym.	14
Rys. 1.4: Klasyfikacja urządzeń mechanicznych z punktu widzenia cech eksploatacyjnych.	16
Rys. 1.5: Klasy urządzeń mechanicznych.	17
Rys. 1.6: Systemy statku powietrznego.	19
Rys. 1.7: Hierarchiczna struktura konstrukcyjna systemu według [Waż1990].	20
Rys. 1.8: Model systemu antropotechnicznego.	21
Rys. 1.9: Proces eksploatacji urządzenia [Fig1996].	22
Rys. 1.10: Budowa systemu ekspertowego.	24
Rys. 1.11: Przykładowe systemy ekspertowe zastosowane w eksploatacji urządzeń.	24
Rys. 1.12: Systemy ekspertowe w technice lotniczej.	25
Rys. 1.13: Dwuwymiarowa przestrzeń stanów eksploatowanego urządzenia [Paw1996].	27
Rys. 1.14: Wielowymiarowa przestrzeń stanów.	28
Rys. 1.15: Siły oddziałujące na samolot podczas lotu.	30
Rys. 1.16: Zderzenia samolotów z ptakami nad lotniskami od 1984 do 1994 roku na 100000 h nalotu [Bar1994].	33
Rys. 1.17: Metody obsługiwanie technicznego statków powietrznych.	34
Rys. 1.18: Chwilowa i uśredniona intensywność użytkowania statku powietrznego: 1 – lot statku powietrznego, 2 – okres postoju.	40
Rys. 1.19: Pracochłonność obsługiwanie samolotów wojskowych na jedną godzinę lotu [Bła2003].	43
Rys. 1.20: Ranking samolotów wojskowych pod względem podatności obsługowej [Bła2003].	43
Rys. 2.1: Klasyfikacja uszkodzeń [Cyu2000].	47
Rys. 2.2: Klasy wskaźników niezawodnościowych.	49
Rys. 2.3: Krzywa Lorenza przebiegu procesu zużywania np. w $[10^{-3} \text{ mm/h}]$; z – zużycie; z_g – zużycie graniczne; z_d – umowne zużycie przy docieraniu.	52
Rys. 2.4: Określenie zasobu pracy urządzenia na podstawie pomiarów zużycia [Cyu2000].	54
Rys. 2.5: Funkcja zasobu zużycia [Paw1996].	54
Rys. 2.6: Uszkodzenia w czasie eksploatacji statków powietrznych.	56
Rys. 2.7: Rodzaje nadmiarów w technice lotniczej.	60
Rys. 2.7: Wykres zmiennej Pracochłonność.	65
Rys. 2.8: Pracochłonność napraw podzespołów statków powietrznych.	66
Rys. 2.9: Podział pracochłonności napraw statków powietrznych ze względu na rodzaj obsług.	66
Rys. 2.10: Podział pracochłonności napraw płatowców ze względu na rodzaj awarii.	68
Rys. 2.11: Podział pracochłonności napraw płatowców ze względu na rodzaj obsług.	68
Rys. 2.12: Podział pracochłonności napraw silnika ze względu na rodzaj awarii.	69
Rys. 2.13: Podział pracochłonności napraw silników ze względu na rodzaj obsług.	70

Rys. 2.14: Podział pracochłonności napraw URE ze względu na rodzaj awarii.	71
Rys. 2.15: Podział pracochłonności napraw URE ze względu na rodzaj obsługi.....	72
Rys. 2.16: Podział pracochłonności napraw osprzętu ze względu na rodzaj awarii.....	73
Rys. 2.17: Podział pracochłonności napraw osprzętu ze względu na rodzaj obsług.....	73
Rys. 3.1: Podział prognoz.....	78
Rys. 3.2: Podział szeregów danych.....	82
Rys. 3.3: Podstawowe grupy metod prognozowania.....	84
Rys. 3.4: Kryteria stosowane podczas selekcji danych.....	86
Rys. 3.5: Poszczególne typy trendów: liniowy, wykładniczy i gasnący.....	88
Rys. 3.6: Sezonowość addytywna i multiplikatywna.....	89
Rys. 3.7: Metody wyrównywania szeregów czasowych.....	90
Rys. 3.8: Modele wyrównywania wykładniczego.....	95
Rys. 3.9: Etapy iteracyjnego podejścia do budowania modeli [Box1983].....	108
Rys. 4.1: Opracowany przez autora algorytm prognozowania pracochłonności napraw.....	118
Rys. 4.2: Wykres zmiennej Pracochłonność – okresy 1- dniowe.....	120
Rys. 4.3: Wykres analizy widmowej zmiennej Pracochłonność [okresy 1 – dniowe].....	121
Rys. 4.4: Wykresy zmiennej Pracochłonność i zmiennej przekształconej filtrem 4253H [okresy 1 – dniowe].....	122
Rys. 4.5: Wykres analizy widmowej zmiennej Pracochłonność przekształconej filtrem 4253H [okresy 1-dniowe].....	122
Rys. 4.6: Wykres zmiennej Pracochłonność po agregacji na okresy miesięczne.....	123
Rys. 4.7: Wykres analizy widmowej zmiennej Pracochłonność i zmiennej Pracochłonność przekształconej filtrem 4325 H.....	123
Rys. 4.8: Wykres analizy widmowej wybranych zmiennych: Płatowiec i URE.....	124
Rys. 4.9: Wykres zmiennej Pracochłonność oraz jej przekształcenia przy pomocy filtra.....	125
Rys. 4.10: Wyniki dekompozycji sezonowej w przypadku modelu addytywnego.....	126
Rys. 4.11: Wykres wskaźnika sezonowości w przypadku modelu addytywnego.....	126
Rys. 4.12: Wyniki dekompozycji sezonowej w przypadku modelu multiplikatywnego.....	127
Rys. 4.13: Wykres wskaźnika sezonowości w przypadku modelu multiplikatywnego.....	128
Rys. 4.14: Wyniki dekompozycji sezonowej w przypadku modelu addytywnego oraz zmiennej Płatowiec.....	129
Rys. 4.15: Wykres wskaźnika sezonowości w przypadku modelu addytywnego oraz zmiennej Płatowiec.....	129
Rys. 4.16: Wyniki dekompozycji sezonowej w przypadku modelu multiplikatywnego.....	130
Rys. 4.17: Wykres wskaźnika sezonowości w przypadku modelu multiplikatywnego oraz zmiennej Płatowiec.....	130
Rys. 4.18: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, bez przekształcenia danych.....	131
Rys. 4.19: Wykresy autokorelacji i histogramy reszt w przypadku modeli wyrównywania wykładniczego zmiennej Pracochłonność oraz danych przedstawionych w tabeli 4.2.....	132
Rys. 4.20: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po przekształceniu danych filtrem 4253H.....	133
Rys. 4.21: Wykresy autokorelacji i histogramy reszt różnych modeli zmiennej Pracochłonność, po przekształceniu danych filtrem 4253H (tabela 4.3).....	133
Rys. 4.22: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po wygładzeniu $\alpha = 0,1 \div 0,9$	134

Rys. 4.23: Wykresy autokorelacji i histogramy reszt w przypadku modeli zmiennej Pracochłonność z trendem gasnącym i składnikiem sezonowym addytywnym i multiplikatywnym oraz szeregiem przekształconym oraz $\alpha=0,4$	135
Rys. 4.24: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po przekształceniu danych średnią ruchomą N-2 punktową.....	136
Rys. 4.25: Wykresy autokorelacji i histogramy reszt w przypadku różnych modeli zmiennej Pracochłonność, po przekształceniu danych N-2 punktową średnią ruchomą (tabela 4.5).	136
Rys. 4.26: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku modeli wyrównywania wykładniczego, po przekształceniu danych medianą ruchomą N-3 punktową.....	137
Rys. 4.27: Wykres autokorelacji histogramy reszt zmiennej Płatowiec w przypadku modeli przedstawionych w tabeli 4.7 (oprócz modeli: brak trendu, brak składnika sezonowego i trend gasnący, brak składnika sezonowego).	138
Rys. 4.28: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego bez przekształcenia danych.....	139
Rys. 4.29: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego przy danych przekształconych filtrem.	140
Rys. 4.30: Wykresy autokorelacji i histogramy reszt modeli zmiennej Płatowiec, przefiltrowanych za pomocą filtra 4253H (tabela 4.8).	141
Rys. 4.31: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego, przy danych przekształconych średnią ruchomą N-2 punktową.....	142
Rys. 4.32: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego, przy danych przekształconych medianą ruchomą N-3 punktową.....	143
Rys. 4.33: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku modeli wyrównywania wykładniczego, po wygładzeniu danych przy $\alpha = 0,1 \div 0,9$	144
Rys. 4.34: Wykresy autokorelacji i histogramy reszt w przypadku wybranych modeli przedstawionych w tabeli 4.11.....	144
Rys. 4.35: Wykresy prognoz dla zmiennej Płatowiec w 2000 r w przypadku najlepiej pasujących modeli wyrównywania wykładniczego.....	145
Rys. 4.36: Wykresy prognoz dla zmiennej Płatowiec w latach 2001 – 2002 w przypadku modelu z trendem gasnącym i składnikiem sezonowym addytywnym.	146
Rys. 4.37: Wykres współczynników: a) autokorelacji; b) autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat.	147
Rys. 4.38: Prognoza dla zmiennej Pracochłonność przy danych z 9 lat w przypadku modelu ARIMA (0,0,1)(0,1,1).	148
Rys. 4.39: Wykres współczynników: a) autokorelacji reszt; b) autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat oraz modelu (0,0,1)(0,1,1).	148
Rys. 4.40: Wykres funkcji autokorelacji zmiennej Pracochłonność w przypadku danych z 9 lat przekształconych filtrem 4253H.	149
Rys. 4.41: Wykresy prognoz dla zmiennej Pracochłonność w przypadku danych przekształconych filtrem 4253H oraz modeli ARIMA.....	150
Rys. 4.42: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłonność przy danych z 9 lat przekształconych filtrem 4253H: a) model (1,0,2)(0,1,1); b) model (1,0,0)(0,1,1).	151

Rys. 4.43: Wykresy współczynników autokorelacji reszt i współczynników autokorelacji cząstkowej zmiennej Pracochłonność przy danych z 9 lat przekształconych filtrem 4253H: a) model (2,0,0)(0,1,0) b) model (1,0,1)(0,1,0).	151
Rys. 4.44: Wykres współczynników autokorelacji zmiennej Pracochłonność w przypadku danych z 9 lat przekształconych N-2 punktową średnią ruchomą.	152
Rys. 4.45: Prognoza dla zmiennej Pracochłonność w 2000 r w przypadku szeregu przekształconego N-2 pt. średn. ruch. oraz modelu ARIMA (0,0,1)(0,1,1).	152
Rys. 4.46: Wykres współczynników autokorelacji reszt zmiennej Pracochłonność w przypadku danych z 9 lat przekształconych N-2 punktową średnią ruchomą: a) autokorelacja reszt modelu (0,0,1)(0,1,1) b) autokorelacja cząstkowa reszt modelu (0,0,1)(0,1,1).	153
Rys. 4.47: Wykres współczynników autokorelacji zmiennej Pracochłonność przy danych z 9 lat przekształconych medianą ruchomą N-3 punktową.	153
Rys. 4.48: Prognoza dla zmiennej Pracochłonność w przypadku szeregu przekształconego N-3 pt. medianą ruch. oraz modelu ARIMA (1,0,0)(0,1,1).	154
Rys. 4.49: Wykres współczynników autokorelacji reszt zmiennej Pracochłonność przy danych z 9 lat przekształconych medianą ruchomą N-3 punktową a) autokorelacja reszt modelu (1,0,0)(0,1,1) b) autokorelacji cząstkowa reszt modelu (1,0,0)(0,1,1).	154
Rys. 4.50: Prognozy dla zmiennej Pracochłonność w przypadku modeli ARIMA oraz szeregu przekształconego wygładzaniem przy $\alpha = 0,1 \div 0,9$	155
Rys. 4.51: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat w zależności od alfa z przedziału $0,1 \div 0,3$ (tabela 4.18).	156
Rys. 4.52: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat w zależności od alfa z przedziału $0,4 \div 0,6$ (tabela 4.18).	156
Rys. 4.53: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej zmiennej Pracochłonność w przypadku danych z 9 lat w zależności od alfa z przedziału $0,7 \div 0,9$ (tabela 4.18).	157
Rys. 4.54: Wykres współczynników autokorelacji i autokorelacji cząstkowej zmiennej Płatowiec.	157
Rys. 4.55: Wykres zmiennej Płatowiec po różnicowaniu.	158
Rys. 4.56: Wykres współczynników autokorelacji zmiennej Płatowiec po różnicowaniu.	159
Rys. 4.57: Prognozy dla zmiennej Płatowiec w 2000 r (modele ARIMA).	160
Rys. 4.58: Wykresy współczynników autokorelacji reszt i autokorelacji cząstkowej wybranych modeli prognozy dla zmiennej Płatowiec w przypadku danych z 9 lat: a) autokorelacja reszt i autokorelacja cząstkowa modelu (1,0,1)(0,1,1) b) autokorelacja reszt i autokorelacja cząstkowa modelu (1,0,1)(1,1,1).	160
Rys. 4.59: Prognozy dla zmiennej Płatowiec w latach 2001 –2002 (modele ARIMA). ...	161
Rys. 4.60: Wykres współczynników a) autokorelacji reszt; b) autokorelacji cząstkowej reszt zmiennej Płatowiec przy danych z 9 lat przekształconych filtrem 4253H.	161
Rys. 4.61: Prognozy dla zmiennej Płatowiec w 2000 r w przypadku szeregu przekształconego filtrem 4253H (modele ARIMA).	162
Rys. 4.62: Wykres współczynników autokorelacji reszt wybranych modeli zmiennej Pracochłonność w przypadku danych z 9 lat przekształconych filtrem 4253H: a) autokorelacja reszt i autokorelacja cząstkowa reszt modelu (1,0,0)(0,1,0) b) autokorelacja reszt i autokorelacja cząstkowa reszt modelu (0,0,1)(0,1,0).	162

Rys. 4.63: Wykres współczynników autokorelacji zmiennej Płatowiec w przypadku danych z 9 lat przekształconych N-2 punktową średnią ruchomą.	163
Rys. 4.64: Prognoza dla zmiennej Płatowiec w 2000 r w przypadku szeregu przekształconego N-2 pt. średn. ruch. oraz modelu ARIMA (0,0,2)(0,1,1).	164
Rys. 4.65: Wykres współczynników a) autokorelacji reszt zmiennej Płatowiec w przypadku danych z 9 lat przekształconych N-2 punktową średnią ruchomą oraz modelu (0,0,2)(0,1,1) b) autokorelacja cząstkowa reszt w przypadku modelu (0,0,2)(0,1,1).	164
Rys. 4.66: Wykres współczynników autokorelacji i autokorelacji cząstkowej zmiennej Płatowiec w przypadku danych z 9 lat przekształconych medianą ruchomą N-3 punktową.	165
Rys. 4.67: Prognoza dla zmiennej Pracochłonność w 2000 r w przypadku szeregu przekształconego N-3 pt. medianą ruch. oraz modelu ARIMA (0,0,2)(0,1,1).	165
Rys. 4.68: Wykres współczynników autokorelacji reszt modeli zmiennej Płatowiec w przypadku danych z 9 lat przekształconych medianą ruchomą N-3 punktową a) w modelu (0,0,2)(0,1,1) b) w modelu (0,0,2)(0,1,1).	166
Rys. 4.69: Prognozy otrzymane za pomocą modeli ARIMA dla zmiennej Płatowiec w 2000 r w przypadku szeregu przekształconego wygładzaniem przy alfa z przedziału 0,1 ÷ 0,9.	167
Rys. 4.70: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej modeli zmiennej Płatowiec w przypadku danych z 9 lat w zależności od alfa z przedziału 0,1 ÷ 0,3 (tabela 4.24)	167
Rys. 4.71: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej modeli zmiennej Płatowiec w przypadku danych z 9 lat w zależności od alfa z przedziału 0,4 ÷ 0,6 (tabela 4.24).	168
Rys. 4.72: Wykres współczynników autokorelacji reszt i autokorelacji cząstkowej modeli zmiennej Płatowiec w przypadku danych z 9 lat w zależności od alfa z przedziału 0,7 ÷ 0,9 (tabela 4.25).	168
Rys. 5.1: Schemat budowy neuronu.	171
Rys. 5.2: Przykładowa sztuczna sieć neuronowa.	172
Rys. 5.3: Dwa modele neuronowe silnie zaszumionego systemu; a – model nieprzeuczony, b – model przeuczony [Rej2002].	176
Rys. 5.4: Schemat sieci RBF w przypadku zmiennej Pracochłonność.	183
Rys. 5.5: Wykresy prognoz dla zmiennej Pracochłonność w 2000 r w przypadku sieci neuronowej.	184
Rys. 5.6: Zmiana wartości błędu w trakcie uczenia sieci RBF.	185
Rys. 5.7: Wykres rozkładu wag sieci RBF.	185
Rys. 5.8: Schemat sieci MLP w przypadku zmiennej Pracochłonność oraz danych z 9 lat.	187
Rys. 5.9: Zmiana wartości błędu w trakcie uczenia sieci MLP.	188
Rys. 5.10: Wykresy prognoz dla zmiennej Pracochłonność w przypadku SSN – MLP. ..	188
Rys. 5.11: Wykres rozkładu wag sieci MLP.	189
Rys. 5.12: Schemat sieci RBF w przypadku zmiennej Płatowiec oraz danych z 9 lat.	190
Rys. 5.13: Zmiana wartości błędu w trakcie uczenia sieci RBF.	190
Rys. 5.14: Wykresy prognoz dla zmiennej Płatowiec w przypadku SSN – RBF w 2000 r.	191
Rys. 5.15: Wykres rozkładu wag sieci RBF w przypadku zmiennej Płatowiec.	191
Rys. 5.16: Schemat sieci MLP w przypadku zmiennej Płatowiec oraz danych z 9 lat.	192

Rys. 5.17: Zmiana wartości błędu w trakcie uczenia sieci MLP.	193
Rys. 5.18: Prognoza dla zmiennej Płatowiec w 2000 roku w przypadku SSN – MLP.	193
Rys. 5.19: Wykres rozkładu wag sieci MLP w przypadku zmiennej Płatowiec.	194
Rys. 5.20: Porównanie prognoz dla zmiennej Pracochłonność w 2000 roku przy wykorzystaniu różnych metod prognozowania.	195
Rys. 5.21: Porównanie prognoz dla zmiennej Płatowiec w 2000 roku przy wykorzystaniu różnych metod prognozowania.	195

SPIS TABEL

Tabela 1.1: Etapy eksploatacji statku powietrznego.....	38
Tabela 1.2: Wskaźniki podatności obsługowej w lotnictwie wojskowym [Bła2003].....	42
Tabela 2.1: Statystyki opisowe przedstawionych zmiennych.....	74
Tabela 3.1: Wykresy funkcji ACF i PACF w przypadku modelu autoregresji AR(1).	110
Tabela 3.2: Wykresy funkcji ACF i PACF w przypadku modelu autoregresji AR(2).	110
Tabela 3.3: Wykresy funkcji ACF i PACF w przypadku modelu średniej ruchomej MA(1).	111
Tabela 3.4: Wykresy funkcji ACF i PACF w przypadku modelu średniej ruchomej MA(2).	111
Tabela 3.5: Wykresy funkcji ACF i PACF w przypadku modelu średniej ruchomej ARIMA (1,1).....	112
Tabela 3.6: Przykładowe modele ARIMA.....	113
Tabela 4.1: Wyniki analizy widmowej zmiennej Pracochłonność (dane po agregacji - miesięczne).	124
Tabela 4.2: Wyniki wyrównywania wykładniczego zmiennej Pracochłonność.....	131
Tabela 4.3: Wyniki wyrównywania wykładniczego przy danych przefiltrowanych.....	132
Tabela 4.4: Wyniki wyrównywania wykładniczego przy danych wygładzonych (alfa=0,1÷0,9).	134
Tabela 4.5: Wyniki wyrówn. wykładniczego przy danych przekształconych N-2 pt. średn. ruch.	135
Tabela 4.6: Wyniki wyrówn. wykładniczego przy danych przekształconych N-3 medianą ruch.	137
Tabela 4.7: Wyniki wyrównywania wykładniczego w przypadku zmiennej Płatowiec. ..	138
Tabela 4.8: Wyniki wyrównywania wykładniczego w przypadku zmiennej Płatowiec przy danych przefiltrowanych.....	139
Tabela 4.9: Wyniki wyrówn. wykładn. zmiennej Płatowiec przy danych przekształc. N-2 pt. średn. ruch.....	141
Tabela 4.10: Wyniki wyrówn. wykładniczego zmiennej Płatowiec danych przekształc. N-3 pt. med. ruch.	142
Tabela 4.11: Wyniki wyrówn. wykładni. w przypadku zmiennej Płatowiec oraz danych wygładzonych (alfa=0,1÷0,9).	143
Tabela 4.12: Wartości współczynników ACF w przypadku zmiennej Pracochłonność. ..	146
Tabela 4.13: Wyniki prognozy dla zmiennej Pracochłonność przy danych nie przekształconych.....	147
Tabela 4.14: Wartości współczynników ACF dla zmiennej Pracochłonność oraz danych przefiltrowanych.	149
Tabela 4.15: Wyniki prognozy dla zmiennej Pracochłonność oraz danych przefiltrowanych.	150

Tabela 4.16: Wyniki prognozy dla zmiennej Pracochłonność oraz danych przekształc. N-2 pt. średn. ruch.....	152
Tabela 4.17: Wyniki prognozy dla zmiennej Pracochłonność oraz danych przekształconych N-3 pt. med. ruch.	154
Tabela 4.18: Wyniki prognozy dla zmiennej Pracochłonność oraz danych wygładzonych przy $\alpha=0,1 \div 0,9$	155
Tabela 4.19: Współczynniki ACF dla zmiennej Płatowiec.	158
Tabela 4.20: Wyniki prognozy dla zmiennej Płatowiec przy danych nie przekształconych.	159
Tabela 4.21: Wyniki prognozy dla zmiennej Płatowiec przy danych przefiltrowanych 4253H.....	162
Tabela 4.22: Prognoza dla zmiennej Płatowiec przy danych przekształconych N-2 pt. średn. ruch.....	163
Tabela 4.23: Prognoza dla zmiennej Płatowiec przy danych przekształc. N-3 pt. medianą ruch.	165
Tabela 4.24: Prognoza dla zmiennej Płatowiec przy danych wygładzonych, przy $\alpha=0,1 \div 0,9$	166
Tabela 5.1: Wyniki automatycznego poszukiwania architektury sieci RBF w przypadku zmiennej Pracochłonność.....	181
Tabela 5.2: Wyniki uczenia sieci RBF.	183
Tabela 5.3: Wyniki błędów prognozy w przypadku sieci RBF oraz zmiennej Pracochłonność.	184
Tabela 5.4: Wyniki poszukiwania architektury sieci MLP w przypadku zmiennej Pracochłonność.	186
Tabela 5.5: Wyniki poszukiwania sieci MLP w przypadku zmiennej Pracochłonność.	186
Tabela 5.6: Wyniki uczenia sieci MLP.....	187
Tabela 5.7: Wyniki błędów prognozy SSN - MLP w przypadku zmiennej Pracochłonność.	187
Tabela 5.8: Wyniki poszukiwania sieci RBF w przypadku zmiennej Płatowiec.	189
Tabela 5.9: Wyniki uczenia sieci RBF.	190
Tabela 5.10: Wyniki błędów prognozy SSN - RBF w przypadku zmiennej Płatowiec.	191
Tabela 5.11: Wyniki poszukiwania sieci MLP w przypadku zmiennej Płatowiec.....	192
Tabela 5.12: Wyniki uczenia sieci MLP.....	192
Tabela 5.13: Wyniki błędów prognozy SSN - MLP w przypadku zmiennej Płatowiec..	193
Tabela Dane miesięczne usuwania awarii [Roboczogodziny].....	211

ZAŁĄCZNIK

Tabela Dane miesięczne usuwania awarii [Roboczogodziny]

	DATA	PRACOCHL	PLATOWIEC	SILNIK	OSPRZĘT	URE	RESURS GOLENI	WYMIANA SILNIKA
1990	Lis-1990	18	0	0	0	18		
	Gru-1990	50	8	10	4	28		
1991	Sty-1991	263	16	144	37	66		
	Lu-1991	0	0	0	0	0		
	Mar-1991	90	80	2	0	8		
	Kwi-1991	754	76	177	0	21		480
	Maj-1991	244	99	114	19	12		
	Cze-1991	388	125	219	36	8		
	Lip-1991	966	121	226	19	0		600
	Sie-1991	114	114	0	0	0		
	Wrz-1991	680	144	249	31	16		240
	Paź-1991	632	44	284	40	24		240
	Lis-1991	0	0	0	0	0		
Gru-1991	18	12	0	0	6			
1992	Sty-1992	16	16	0	0	0		
	Lu-1992	163	66	73	0	24		
	Mar-1992	478	88	109	8	33		240
	Kwi-1992	102	82	0	0	20		
	Maj-1992	494	158	196	6	14		120
	Cze-1992	642	165	200	23	14		240
	Lip-1992	52	52	0	0	0		
	Sie-1992	924	124	168	32	0		600
	Wrz-1992	483	172	63	0	8		240
	Paź-1992	48	48	0	0	0		
	Lis-1992	63	12	32	0	19		
Gru-1992	36	24	0	0	12			
1993	Sty-1993	335	16	246	51	22		
	Lu-1993	251	84	132	1	34		
	Mar-1993	326	97	159	46	24		
	Kwi-1993	140	102	24	0	14		
	Maj-1993	113	113	0	0	0		
	Cze-1993	225	177	40	0	8		
	Lip-1993	532	74	172	30	16		240
	Sie-1993	415	195	191	21	8		
	Wrz-1993	604	166	156	18	24		240
	Paź-1993	254	16	136	54	48		
	Lis-1993	493	34	137	21	58		240
Gru-1993	12	12	0	0	0			
1994	Sty-1994	208	81	84	29	14		
	Lu-1994	928	107	265	38	38		480
	Mar-1994	388	126	185	34	43		
	Kwi-1994	174	133	25	2	14		
	Maj-1994	315	142	151	6	16		
	Cze-1994	638	184	174	28	12		240
	Lip-1994	248	202	38	0	8		
	Sie-1994	475	175	60	0	0		240
	Wrz-1994	270	163	66	18	23		
	Paź-1994	741	117	120	0	24		480
	Lis-1994	390	80	188	56	66		
Gru-1994	230	60	122	24	24			
1995	Sty-1995	20	20	0	0	0		
	Lu-1995	511	121	99	14	37		240
	Mar-1995	112	112	0	0	0		
	Kwi-1995	77	77	0	0	0		
	Maj-1995	98	64	10	8	16		
	Cze-1995	33	33	0	0	0		
	Lip-1995	531	198	93	0	0		240
	Sie-1995	400	175	176	35	14		

	Wrz-1995	150	149	0	0	1		
	Paź-1995	1072	119	199	0	34		720
	Lis-1995	84	84	0	0	0		
	Gru-1995	160	78	40	8	34		
1996	Sty-1996	364	70	188	42	64		
	Lu-1996	486	131	158	28	42	127	
	Mar-1996	187	143	0	1	43		
	Kwi-1996	369	137	165	24	43		
	Maj-1996	365	164	168	17	16		
	Cze-1996	588	180	136	24	8	63	240
	Lip-1996	504	170	212	51	8		
	Sie-1996	121	121	0	0	0		
	Wrz-1996	212	211	0	1	0		
	Paź-1996	397	106	182	43	66		
	Lis-1996	380	98	202	24	56		
	Gru-1996	561	79	144	41	57		240
1997	Sty-1997	42	42	0	0	0		
	Lu-1997	466	156	166	38	42	64	
	Mar-1997	474	167	196	25	86		
	Kwi-1997	147	147	0	0	0		
	Maj-1997	306	187	87	14	18		
	Cze-1997	444	210	163	63	8		
	Lip-1997	423	202	188	24	9		
	Sie-1997	398	211	151	22	14		
	Wrz-1997	39	39	0	0	0		
	Paź-1997	297	136	80	10	71		
	Lis-1997	333	114	131	26	62		
	Gru-1997	342	113	109	56	64		
1998	Sty-1998	214	142	12	15	45		
	Lu-1998	140	140	0	0	0		
	Mar-1998	740	140	120	0	0		480
	Kwi-1998	86	86	0	0	0		
	Maj-1998	78	78	0	0	0		
	Cze-1998	393	192	133	54	14		
	Lip-1998	244	209	31	4	0		
	Sie-1998	501	193	181	52	12	63	
	Wrz-1998	85	85	0	0	0		
	Paź-1998	365	131	105	64	65		
	Lis-1998	199	90	46	12	51		
	Gru-1998	723	105	147	44	67		360
1999	Sty-1999	693	70	254	0	9		360
	Lu-1999	268	122	66	46	34		
	Mar-1999	290	141	49	8	92		
	Kwi-1999	358	136	182	24	16		
	Maj-1999	405	158	194	36	17		
	Cze-1999	121	121	0	0	0		
	Lip-1999	670	206	185	31	8		240
	Sie-1999	372	177	162	26	7		
	Wrz-1999	432	185	196	27	24		
	Paź-1999	340	114	134	20	72		
	Lis-1999	442	76	247	0	56	63	
	Gru-1999	374	90	177	34	73		
2000	Sty-2000	550	83	138	23	66		240
	Lu-2000	313	126	99	34	54		
	Mar-2000	400	155	122	59	64		
	Kwi-2000	357	145	130	38	44		
	Maj-2000	333	162	115	42	14		
	Cze-2000	502	178	186	59	15	64	
	Lip-2000	893	207	192	58	12	64	360
	Sie-2000	317	187	130	0	0		
	Wrz-2000	852	179	174	58	18	63	360
	Paź-2000	384	126	159	32	67		
	Lis-2000	638	87	172	59	80		240
	Gru-2000	332	75	144	29	84		
RAZEM		42320	13963	12962	2362	2982	571	9480