

POLITECHNIKA WROCŁAWSKA

Wydział Elektroniki

ROZPRAWA DOKTORSKA

mgr inż. Michał Błędowski

Analiza biosygnatów dla sterowania decyzyjnego protezą dłoni

Promotor:
dr hab. inż. Elżbieta Roszkowska

Promotor pomocniczy:
dr inż. Andrzej Wołczowski

Wrocław 2021

Składam podziękowania Panu dr. inż. Andrzejowi Wołczowskiemu za cenne uwagi oraz za udzielenie wszechstronnej pomocy naukowej w czasie studiowania i pisania niniejszej pracy.

Dziękuję Pani dr hab. inż. Elżbiecie Roszkowskiej za opiekę promotorską oraz za nieocenioną pomoc.

Dziękuję Rodzicom Danucie i Januszowi za poświęcony czas i motywację do dalszej pracy w chwilach zwątpienia. Bez wsparcia, które od Was otrzymałem, nie byłoby mnie tu, gdzie jestem.

Dziękuję Żonie Annie za wyrozumiałość i cierpliwość. Za wiarę we mnie i za to, że zawsze mogłem na Ciebie liczyć.

STRESZCZENIE

Praca została poświęcona problemowi rozpoznawania wieloetapowego dla potrzeb sterowania robotyczną protezą dłoni. W odróżnieniu od klasycznego podejścia zostało zaproponowane rozwiązanie, w którym proces sterowania zostaje rozpoczęty przed końcem rejestracji pełnego sygnału. Zaproponowany sterownik rozpoznawania wieloetapowego współdziała z klasycznym systemem rozpoznawania ruchów. Służy do sterowania kinematycznym urządzeniem końcowym, jakim jest robotyczna proteza. Pozwala on rozpocząć ruch protezy jeszcze przed końcem właściwego przyporządkowania sygnału do jednej z klas poprzez łączenie tychże klas w grupy ruchów i klasyfikowanie sygnału do jednej z takich grup.

Wraz z rosnącą długością zarejestrowanego sygnału liczba klas w grupie systematycznie się zmniejsza. Dzięki odrzucaniu niepasujących klas w trakcie trwania pomiaru możliwe jest rozpoczęcie ruchu jeszcze przed zakończeniem etapu akwizycji danych.

Prezentowane podejście zakłada, że we wczesnych fazach rejestracji sygnału pomiarowego można zaklasyfikować sygnał do zbioru kilku ruchów. Algorytm nie podejmuje jeszcze decyzji, jaka będzie końcowa komenda systemu, ale umożliwia rozpoczęcie ruchu protezy. Kolejne iteracje algorytmu powodują zmniejszenie ilości klas w grupie do której należy sygnał, a więc doprecyzowanie intencji ruchu (vide punkt 4.6).

Słowa kluczowe: *sterowanie decyzyjne, elektromiografia, robotyczna proteza, ekstrakcja, selekcja, klasyfikacja, rozpoznawanie obiektów, klasyfikacja wieloetapowa*

ABSTRACT

The work is on the problem of multi-stage recognition for the control of a robotic hand prosthesis. In contrast to the classic approach, a solution has been proposed in which the control process is started before the end of recording the full signal. The proposed multi-stage recognition controller interacts with the classic motion recognition system. It is used for kinematic control of the end device, which is a robotic prosthesis. It allows the prosthesis movement to begin before the end of the actual signal assignment to one of the classes by combining these classes into movement groups and classifying the signal into one of such groups.

Along with the increasing length of the recorded signal, the number of classes in the group is systematically decreasing. Because of the rejection of mismatched classes during the measurement, it is possible to start the movement even before the end of the data acquisition stage.

The presented approach assumes that in the early stages of recording a measurement signal, a signal can be classified into a set of several movements. The algorithm does not yet decide what the final command of the system will be, but allows the prosthesis to start moving. Subsequent iterations of the algorithm reduce the number of classes in the group to which the signal belongs, and thus make the intention of the traffic more precise (see chapter 4.6).

Keywords: *decision control, electromyography, robotic prosthesis, extraction, selection, classification, pattern recognition, sequential recognition*

Spis treści

1	Wprowadzenie	5
1.1	Wstęp	5
1.2	Opis problemu	6
1.3	Budowa przedramienia	7
1.4	Sygnaly biologiczne	12
2	Cel i zakres pracy	15
2.1	Teza	15
2.2	Cel pracy	15
2.3	Otrzymane wyniki	16
2.4	Organizacja rozprawy	17
3	Metody i algorytmy	19
3.1	Podjezcie jednoetapowe	19
3.1.1	Dane wejsciowe	19
3.1.2	Ekstrakcja cech	19
3.1.2.1	Cechy czasowe	21
3.1.2.2	Cechy czestotliwosciowe	23
3.1.2.3	Cechy czasowo – czestotliwosciowe	23
3.1.3	Procedury selekcji	24
3.1.3.1	Problem wymiarowosci	26
3.1.3.2	Filtry	27
3.1.3.3	Wrappery	28
3.1.4	Klasyfikatory	30
3.1.4.1	Klasyfikator K najblizszych sasiodow	30
3.1.4.2	Maszyna wektorow nośnych	31
3.1.4.3	Naiwny klasyfikator Bayesa	32
3.2	Podjezcie wieloetapowe	33
3.2.1	Dane wejsciowe	35

3.2.2	Ekstrakcja cech	35
3.2.3	Selekcja	35
3.2.4	Schemat decyzyjny	35
3.2.5	Opracowanie drzewa decyzyjnego	36
3.2.5.1	Przegląd zupełny	36
3.2.5.2	Analiza statystyczna	36
3.3	Dynamiczna transformacja czasowa	38
3.4	Test Shapiro-Wilka	42
3.5	Test t -studenta	42
4	Badania eksperymentalne	45
4.1	Akwizycja danych	45
4.2	Stanowisko badawcze	45
4.2.1	System do akwizycji danych pomiarowych	45
4.2.2	Opaska The Myo	47
4.3	Opis eksperymentu pomiarowego	48
4.3.1	Baza sygnałów EMG i MMG	49
4.3.2	Opis zasobu	49
4.3.3	Metodyka prowadzenia pomiarów	49
4.3.3.1	Opis ruchów	50
4.3.3.2	Organizacja bazy danych	53
4.3.3.3	Dostępność	54
4.3.4	Baza sygnałów EMG, MMG i postury dłoni	54
4.4	Wyznaczanie współczynnika algorytmu kNN	56
4.4.1	Założenia	56
4.4.2	Cel	56
4.4.3	Przebieg	56
4.4.4	Dyskusja	57
4.5	Klasyczny proces rozpoznawania	58
4.5.1	Założenia	58
4.5.2	Cel	59
4.5.3	Przebieg	59
4.5.4	Dyskusja	61
4.6	Rozpoznawanie wieloetapowe	63
4.6.1	Założenia	63
4.6.2	Cel	64
4.6.3	Przebieg	64
4.6.3.1	Wstępna analiza przydatności sygnału pomiarowego	64

SPIS TREŚCI	3
4.6.3.2 Klasyfikacja sekwencyjna sygnału o rosnącej długości . . .	70
4.6.3.3 Przegląd zupełny z warunkiem na średni poziom rozpoznawania	72
4.6.3.4 Analiza statystyczna	80
4.6.4 Dyskusja	85
5 Przyszłe badania	89
6 Podsumowanie	91

Rozdział 1

Wprowadzenie

1.1 Wstęp

Współczesna rehabilitacja medyczna, dla poprawy stanu zdrowia i jakości życia pacjentów, wykorzystuje coraz bardziej zaawansowane technologicznie urządzenia zwane protezami.

Na przestrzeni ostatnich lat można zaobserwować ciągle rosnące zainteresowanie tematyką robotycznych protez. Często zastępują one człowiekowi kończynę utraconą w wypadku, na skutek choroby lub niewykształconą we wczesnym etapie rozwoju. Dzięki mnogości zastosowań mogą one pomagać w życiu codziennym i zawodowym umożliwiając użytkownikowi wykonywanie skomplikowanych chwytów [1,2].

Robotyczne protezy dłoni są również wykorzystywane jako manipulatory w nowoczesnych robotach humanoidalnych. W tym przypadku mogą pełnić zarówno rolę chwytaków, jak również pomagają w komunikacji z człowiekiem. Poprzez gestykulację robot jest w stanie wyrażać emocje [3,4].


Kolejnym obszarem, w którym zastosowane zostały robotyczne protezy, jest chirurgia zabiegowa. Lekarz podczas skomplikowanych operacji posługuje się robotem medycznym. W tym przypadku precyzja i dokładność robotycznych ramion jest niezwykle istotna. Ich dokładność i niezawodność ma bezpośrednio wpływ na ludzkie życie [5,6].

Efektory w postaci robotycznej dłoni stosowane są również w robotach do zadań specjalnych np. saperskich, górniczych. Podobnie jak w przypadku robotów medycznych bardzo istotna jest tutaj precyzja. Jednak w tym przypadku ich główną zaletą jest zastąpienie człowieka w niebezpiecznym otoczeniu zagrażającym jego zdrowiu, a nawet życiu [7].

Spośród wielu możliwości zastosowań robotycznych protez, badania przedstawione w pracy dotyczą kończyny górnej człowieka. Robotyczna proteza w takim przypadku zwiększa nie tylko komfort życia użytkownika na codzień, lecz również pozwala powrócić na rynek pracy.

W zależności od budowy i zaawansowania sterownika, robotyczna dłoń pozwala na wykonywanie skomplikowanych manipulacji z otoczeniem, a nawet poprzez sprzężenie zwrotne informacji od maszyny do człowieka możliwe jest w pewnym sensie czucie manipulowanych przedmiotów.

Problem budowy robotycznej protezy jest interdyscyplinarnym zagadnieniem łączącym ze sobą takie dziedziny nauki jak robotyka, mechanika, informatyka i medycyna.



Rysunek 1.1: Liczba amputacji urazowych w kolejnych latach.

Potrzebę badań w tej dziedzinie ilustruje rysunek 1.1 [8–16]. Przedstawia on liczbę amputacji urazowych w Polsce w kolejnych latach. Pomimo iż tendencja zdaje się być malejąca, skala zjawiska nadal jest ogromna.

1.2 Opis problemu

Jakość sterowania bioprotezą charakteryzują zasadniczo trzy parametry:

- liczność repertuaru realizowanych ruchów manipulacyjno – chwytnych,
- niezawodność rozpoznawania intencji ich realizacji,
- czas reakcji systemu na pojawiającą się intencję wykonania ruchu.

Pod względem użyteczności protezy najważniejszym parametrem jest jej niezawodność. Błędne rozpoznanie intencji wykonania ruchu skutkuje niepoprawną manipulacją z otoczeniem, a w konsekwencji koniecznością powtórnego wykonania ruchu. Ponadto błędne rozpoznanie intencji ruchu może spowodować uszkodzenie manipulowanego przedmiotu.

Bogaty repertuar ruchów pozwala na manipulację różnego rodzaju przedmiotami w otaczającej przestrzeni. Stosowane rozwiązania pozwalają na klasyfikację nawet 14 różnych ruchów [17, 18].

Badania przeprowadzone na grupie ludzi pokazały, że czas pomiędzy pojawieniem się intencji ruchu, a reakcją protezy nie może być większy od $125ms$ dla wolno wykonywanych ruchów i $100ms$ dla ruchów szybkich. W przeciwnym wypadku ruchy wykonywane przez robotyczną protezę wydają się nienaturalne dla użytkownika. Opóźnienie pomiędzy pojawieniem się intencji, a rozpoczęciem samego ruchu wprowadza odczuwalny dyskomfort podczas użytkowania [19].

Opracowanie systemu pomiarowego, którego reakcja na pojawienie się intencji ruchu będzie możliwie zbliżona do założonych wartości, pozwoli na budowę robotycznej protezy z naturalnym czasem reakcji. Dzięki temu zwiększy się komfort korzystania z takiego urządzenia, a co za tym idzie podniesie się jakość życia osób, które z takiego urządzenia są zmuszone korzystać.

1.3 Budowa przedramienia

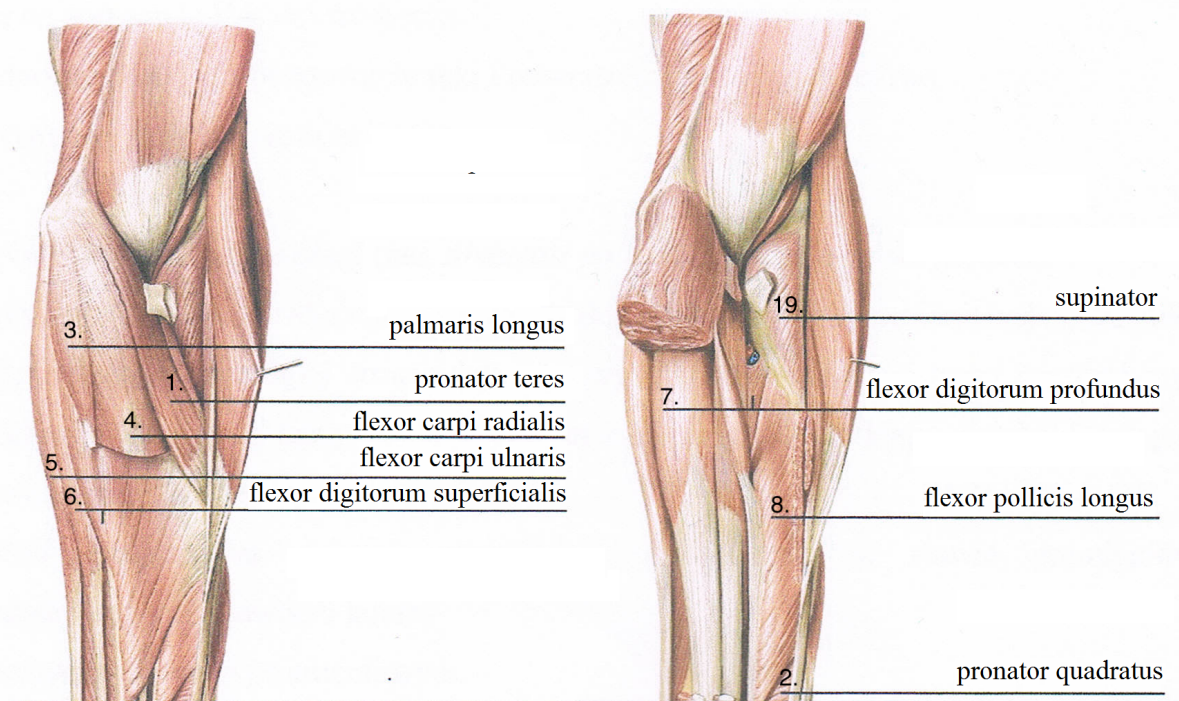
Znajomość anatomicznej budowy przedramienia jest niezwykle istotna podczas planowania rozmieszczenia elektrod pomiarowych. Umieszczenie ich nad interesującymi mięśniami gwarantuje polepszenie rejestrowanego sygnału. Wiedza o budowie została wykorzystana w rozdziale 4.3.1, gdzie opisano eksperyment pomiarowy razem z umiejscowieniem elektrod.

Przedramię człowieka zbudowane jest z 19 mięśni. W zależności od położenia pełnią różne funkcje. Człowiek (poprzez ich napinanie i rozluźnianie) steruje poszczególnymi palcami dłoni [20, 21].

Mięśnie przedramienia (od łokcia do nadgarstka), w zależności od położenia, dzielą się na trzy grupy:

- grupa przednia,
- grupa tylna,
- grupa boczna.

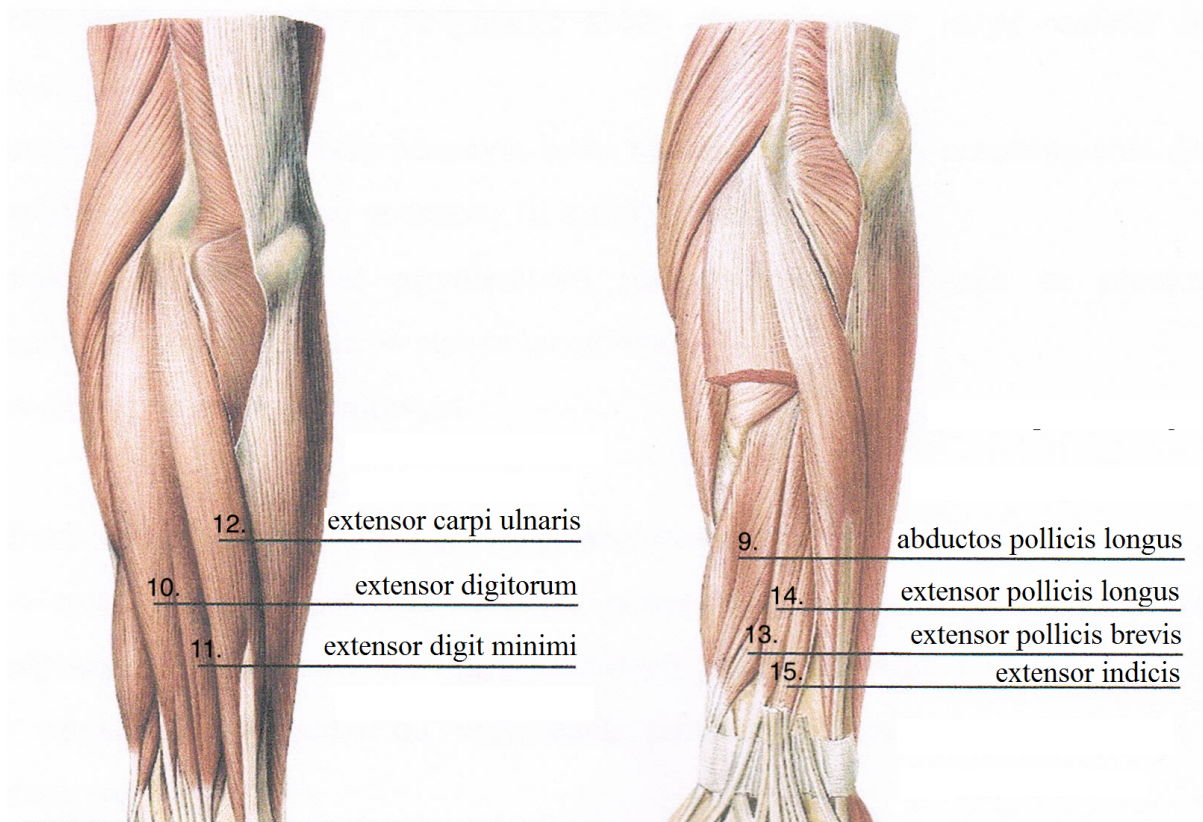
Nazwy polskie i łacińskie poszczególnych mięśni oraz odpowiadające im funkcje zostały zawarte w tabelach 1.1, 1.2 i 1.3 oraz zostały zaznaczone na rysunkach 1.2, 1.3 i 1.4.



Rysunek 1.2: Grupa przednia mięśni przedramienia [21]

Tabela. 1.1: Grupa przednia mięśni przedramienia

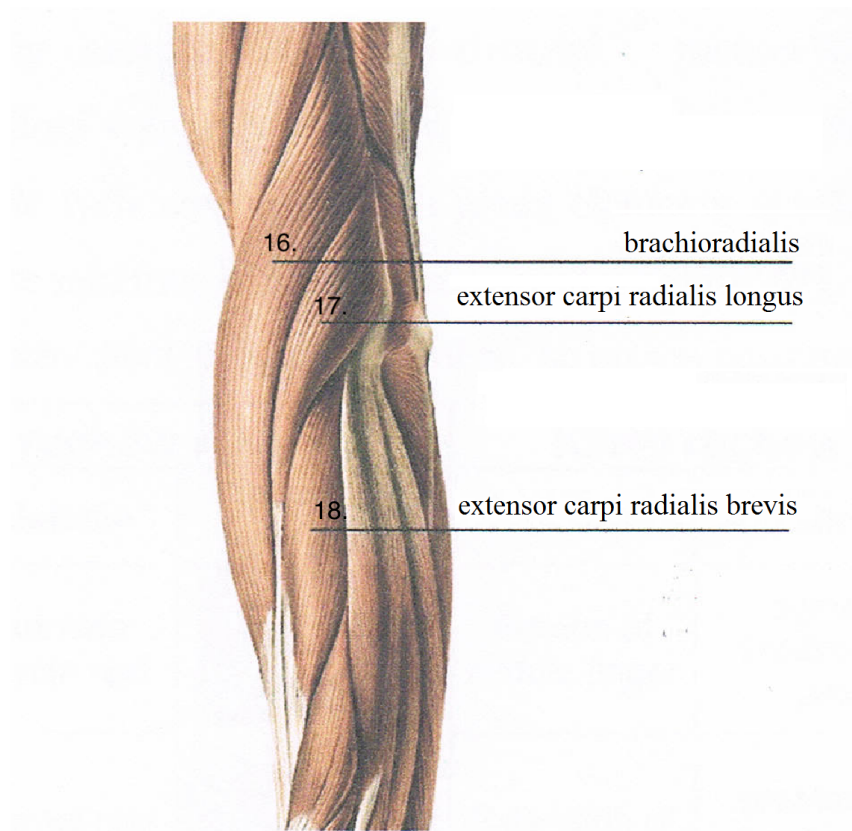
Np.	Nazwa łacińska	Nazwa polska	Funkcja
1.	Pronator teres	Mięsień nawrotny obły	nawracanie przedramienia w stawie promieniowo łokciowym, zginanie stawu łokciowego
2.	Pronator quadratus	Mięsień nawrotny czworoboczny	nawracanie przedramienia
3.	Palmaris longus	Mięsień dłoniowy	nawracanie przedramienia, zginanie stawów ręki i palców w stawach śródrečno - palczkowych
4.	Flexor carpi radialis	Zginacz promieniowy nadgarstka	nawracanie przedramienia, zginanie i odwodzenie ręki w stronę promieniową
5.	Flexor carpi ulnaris	Zginacz łokciowy nadgarstka	przywodzenie i zginanie ręki w stronę łokciową
6.	Flexor digitorum superficialis	Zginacz palców powierzchniowy	zgięcie grzbietowe dłoni, zginanie ręki, zginanie palców
7.	Flexor digitorum profundus	Zginacz palców głęboki	zginanie ręki, przywodzenie ręki, zginanie palców dalszych
8.	Flexor pollicis longus	Zginacz kciuka długi	zginanie ręki, zginanie kciuka



Rysunek 1.3: Grupa tylna mięśni przedramienia [21]

Tabela. 1.2: Grupa tylna mięśni przedramienia

Np.	Nazwa łacińska	Nazwa polska	Funkcja
9.	Abductor pollicis longus	Odwodziciel kciuka długi	odwodzenie kciuka, odwodzenie ręki w stronę promieniową, zginanie ręki
10.	Extensor digitorum	Prostownik palców	prostowanie ręki, przywodzenie ręki
11.	Extensor digiti minimi	Prostownik palca małego	prostowanie palca V, przywodzenie palca V
12.	Extensor carpi ulnaris	Prostownik łokciowy nadgarstka	prostowanie ręki, przywodzenie ręki
13.	Extensor pollicis brevis	Prostownik kciuka krótki	prostowanie kciuka, przywodzenie kciuka
14.	Extensor pollicis longus	Prostownik kciuka długi	prostowanie kciuka we wszystkich stawach
15.	Extensor indicis	Prostownik palca wskazującego	prostowanie ręki, odwodzenie ręki w stronę promieniową



Rysunek 1.4: Grupa boczna mięśni przedramienia [21]

Tabela. 1.3: Grupa boczna mięśni przedramienia

Np.	Nazwa łacińska	Nazwa polska	Funkcja
16.	Brachioradialis	Mięsień ramiennieo - promieniowy	zginanie stawu łokciowego
17.	Extensor carpi radialis longus	Prostownik promieniowy nadgarstka długi	zginanie przedramienia w stawie łokciowym
18.	Extensor carpi radialis brevis	Prostownik promieniowy nadgarstka krótki	prostowanie ręki
19.	Supinator	Odwodziciel	odwracanie ręki, odwracanie przedramienia

1.4 Sygnały biologiczne

Dowolny sygnał generowany przez żywy organizm nazywany jest biosygnalem. Jednym z najpowszechniejszych i najczęściej mierzonych sygnałów biologicznych u człowieka jest temperatura ciała.

Na potrzeby rozpoznawania intencji ruchów najczęściej wykorzystywanym biosygnalem w rozwiązaniach komercyjnych, robotycznych protez jest sygnał elektromiograficzny [17,18]. W badaniach akademickich również często posługuje się sygnałem mechanomiograficznym [22,23] i elektroencefalograficznym [24].

W pracy do badań i symulacji wykorzystano sygnały elektromiograficzne zarejestrowane na przedramieniu dorosłego człowieka. Inne przykładowe sygnały biologiczne zostały wymienione w tabeli 1.4.

Tabela. 1.4: Zestawienie różnego typu sygnałów o charakterze biologicznym.


Skrót	Nazwa angielska	Nazwa polska
EEG	Electroencephalogram	Elektroencefalogram
ECG	Electrocardiogram	Elektrokardiogram
EMG	Electromyogram	Elektromiogram
MMG	Mechanomyogram	Mechanomiogram
EOG	Electrooculography	Elektrookulogram
GSR	Galvanic skin response	Reakcja skórno-galwaniczna
MEG	Magnetoencephalogram	Magnetoencefalogram

Sygnał elektromiograficzny (EMG) jest sygnałem o charakterze elektrycznym. Potencjał elektryczny powstaje wewnątrz komórek mięśniowych dzięki ruchowi jonów (Na^+ , K^+). Proces odbywa się w wyniku pobudzonych do kurczenia się i rozkurczania mięśni.


Powstała w ten sposób zmiana potencjału elektrycznego propaguje przez tkanki i kości aż do powierzchni skóry. Zarejestrowany tam sygnał jest superpozycją sygnałów ze wszystkich komórek mięśniowych. Dodatkowo rejestracja nieinwazyjna zwana jest elektromiografią powierzchniową.

Wartość skuteczna sygnału EMG z mięśni szkieletowych człowieka, w zależności od stopnia ich pobudzenia, może przyjmować wartości z przedziału $0 - 10mV$, a użyteczna energia przyjmuje najwyższe wartości w przedziale $50 - 150Hz$ [25,26].

Na rysunku 1.5a został przedstawiony przykładowy sygnał elektromiograficzny zarejestrowany przy pomocy elektromiografii powierzchniowej (nieinwazyjnie). Długość pomiaru przedstawionym przypadkiem wyniosła 2 sekundy, a rejestracja odbyła się z



(a) Sygnał w dziedzinie czasu



(b) Sygnał w dziedzinie częstotliwości

Rysunek 1.5: Przykładowy sygnał elektromiograficzny zarejestrowany na powierzchni przedramienia i jego widmo

częstotliwością próbkowania równą 1000Hz , co dało 2000 próbek na pomiar. Rysunek 1.5b przedstawia widmo tego sygnału.

Rozdział 2

Cel i zakres pracy

2.1 Teza

W procesie klasyfikacji biosygnarów zastosowanie podejścia rozpoznawania wieloetapowego pozwala na przyspieszenie rozpoczęcia procesu klasyfikacji oraz zwiększenie efektywności robotycznej protezy poprzez przyspieszenie jej reakcji. Poziom dokładności rozpoznawania zmienia się w zależności od tego, jak szybko rozpoczynany jest proces rozpoznawania.

2.2 Cel pracy

Celem pracy jest zaproponowanie rozwiązania pozwalającego na rozpoczęcie procesu rozpoznawania biosygnarów we wczesnych fazach procesu akwizycji sygnału pomiarowego, a dokładniej jeszcze przed zakończeniem pomiaru sygnału elektromiograficznego.

Takie rozwiązanie pozwoli na implementację nowego rodzaju algorytmów na urządzeniach końcowych, korzystających ze sterowania opartego o system wieloetapowej klasyfikacji sygnałów elektromiograficznych. Algorytmy te, z powodu szybszej reakcji na sygnał wejściowy, będą w stanie wiernie odwzorowywać reakcje protezy na pojawienie się chęci wykonania ruchu.

Nowe podejście zakłada, że we wczesnych fazach rejestracji sygnału pomiarowego można zaklasyfikować sygnał do zbioru kilku ruchów zamiast do konkretnego ruchu. Algorytm nie podejmuje jeszcze decyzji, jaka będzie końcowa komenda systemu, ale umożliwia rozpoczęcie ruchu protezy. Kolejne iteracje algorytmu powodują zmniejszenie ilości klas w

grupie, do której należy sygnał, a więc doprecyzowanie ruchu, który ma zostać wykonany przez użytkownika systemu.

Rozwiązanie pozwoli zachować ograniczenie czasowe na rozpoczęcie wykonywania ruchu [19]. W najgorszym wypadku, dzięki rozpoznawaniu wieloetapowemu, czas reakcji sterownika kinematycznego protezy zbliży się do optymalnej wartości.

2.3 Otrzymane wyniki

Przeprowadzone badania zostały opisane w rozdziale 4. W pierwszej kolejności zostały przeprowadzone badania dotyczące wytypowania najlepszego zestawu metod ekstrakcji, selekcji i klasyfikacji cech na potrzeby rozpoznawania biosygnarów. Ocena, jaką się kierowano, była możliwie największa wartość poprawnej klasyfikacji. Dla klasycznego podejścia opisanego w rozdziale 3.1 najlepszą okazała się kombinacja metod krótkoczasowa transformacja Fouriera jako metoda pozyskiwania cech i algorytm k najbliższych sąsiadów jako model klasyfikacji dla 10 sąsiadów. Badania nad wyznaczeniem najlepszego zestawu metod zostały przeprowadzone w rozdziale 4.4 oraz 4.5.

Rozdział 4.6 został poświęcony rozpoznawaniu wieloetapowemu. W pierwszej kolejności został zbadany wpływ długości sygnału pomiarowego na poprawność rozpoznawania dla wybranych metod ekstrakcji cech. Otrzymane wyniki zostały zaprezentowane na rysunkach 4.9 i 4.10. Badanie dotyczyło również wpływu wstępnego podziału sygnału na odcinki o długości $100ms$. Dla każdej z metod ekstrakcji wyniki badania zostały zamieszczone na rysunku 4.11. Dla sygnału bez wstępnego podziału na segmenty $100ms$ najlepsza okazała się krótkoczasowa transformacja Fouriera jako metoda pozyskiwania cech. Dla sygnału wstępnie podzielonego na segmenty najefektywniejszą metodą wyznaczania cech jest szybka transformacja Fouriera. Spośród metod czasowych najlepsza okazała się średnia wartość absolutna. Połączenie na etapie ekstrakcji zbioru cech otrzymanych z najlepszej z metod czasowych i częstotliwościowych zostało przedstawione na rysunku 4.12. Każdorazowo wyniki dla połączonego zestawu metod były pogorszone w porównaniu do krótkoczasowej transformacji Fouriera i polepszone w stosunku do metody czasowej.

Następnie dla klasyfikacji wieloetapowej zostały zbudowane drzewa decyzyjne przy pomocy dwóch zaproponowanych algorytmów:

- przegląd zupełny,
- analiza statystyczna.

Drzewo decyzyjne zbudowane przy pomocy przeglądu zupełnego zostało zaprezentowane na rysunku 4.19. Natomiast drzewo decyzyjne otrzymane za pomocą analizy statystycznej zostało przedstawione na rysunku 4.20.

2.4 Organizacja rozprawy

Praca została podzielona na rozdziały. Rozdział 1 został poświęcony na wprowadzenie w tematykę oraz ogólny zarys problemu. Rozdział 2 zawiera takie części pracy jak teza, cel i otrzymane wyniki. W rozdziale 3 zostały kolejno opisane podejście jednoetapowe i wieloetapowe, jak również wszystkie metody i algorytmy oraz testy statystyczne. W rozdziale 4 zostały opisane wykonane badania dla podejścia jednoetapowego oraz wieloetapowego. Rozdział 6 został poświęcony podsumowaniu, wnioskowi i dalszemu rozwojowi podejścia wieloetapowego.

Rozdział 3

Metody i algorytmy

3.1 Podejście jednoetapowe

Klasyczny schemat procesu rozpoznawania składa się z trzech etapów: ekstrakcji, selekcji, klasyfikacji i poprzedzającego je etapu akwizycji danych pomiarowych (rys. 3.1).

W klasycznym podejściu procesowi poddawany jest cały sygnał zarejestrowany w pojedynczym pomiarze. Wiąże się to z koniecznością czekania na zakończenie pełnego pomiaru, żeby rozpocząć proces przyporządkowywania sygnału do danej klasy ruchu [27, 28].

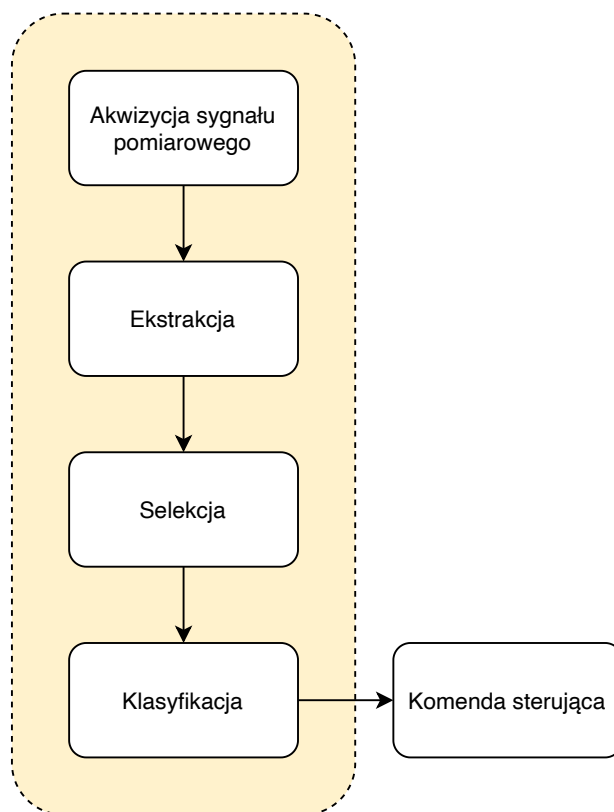
Brak płynności i opóźnienie pomiędzy intencją wykonania ruchu, a samym ruchem niepotrzebnie wstrzymuje proces klasyfikacji ruchu.

3.1.1 Dane wejściowe

Jako dane wejściowe została wykorzystana baza pomiarowa opisana w rozdziale 4.3.3.1. Z całości danych zostały wybrane sygnały elektromiograficzne zarejestrowane na ośmiu niezależnych kanałach. Procedura pomiarowa i rozmieszczenie elektrod zostały opisane we wspomnianym rozdziale.

3.1.2 Ekstrakcja cech

Ekstrakcja cech jest etapem przetwarzania danych pomiarowych. Zarejestrowany sygnał zostaje poddany procesowi ekstrakcji cech. Poprzez zastosowanie odpowiednich algorytmów ekstrakcji zostaje wyłoniony zbiór cech F charakteryzujący interesujące (dla



Rysunek 3.1: Klasyczny proces rozpoznawania.

procesu rozpoznawania) informacje zawarte w sygnale, taki że:

$$F = \{f_1, \dots, f_R\}, \quad (3.1)$$

gdzie:

R – jest liczbą cech w zbiorze.

Na etapie uczenia dodatkowo zbierane są informacje podczas rejestrowania sygnału o klasie, która zostaje wykonana. Informacja dołączona w ten sposób do wyliczonego wektora cech tworzy zestaw danych D i ma postać

$$D = \{(F_1, y), \dots, (F_k, y)\}, \quad (3.2)$$

gdzie:

y – jest przyporządkowaniem do klasy,

k – jest liczbą pomiarów.

Algorytmy ekstrakcji mogą działać w dziedzinie czasu (wyznaczając takie parametry sygnału jak: średnia kwadratowa, średnia wartość absolutna, wariancja, odchylenie standardowe, długość obwiedni, energia, itp. [27]), w dziedzinie częstotliwości (transformacja Fouriera, itp. [29, 30]) lub też czasu i częstotliwości (krótkoczasowa transformacja Fouriera [31]). Można też łączyć cechy uzyskiwane różnymi metodami. Po połączeniu cech sygnałów ze wszystkich kanałów pomiarowych (dla pojedynczego pomiaru) zostaje utworzony wektor cech F . W zależności od zastosowanych algorytmów ekstrakcji cech dąży się do tego, żeby wektor jak najdokładniej charakteryzował klasę, do której należy.

3.1.2.1 Cechy czasowe

Średnia kwadratowa

Średnia kwadratowa jest to pierwiastek ze średniej arytmetycznej kwadratów kolejnych próbek sygnału [32, 33]. Wzór na obliczenie wartości ma postać

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2}, \quad (3.3)$$

gdzie:

x_n – jest n -tą próbką sygnału,

N – jest liczbą próbek sygnału.

Średnia wartość absolutna

Średnia wartość absolutna wyliczana jest jako średnia z wartości bezwzględnych kolejnych próbek sygnału [33]. Wzór na obliczenie wartości ma postać

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N |x_n|. \quad (3.4)$$

Wariancja

Wariancja jest miarą zmienności liczoną jako średnia arytmetyczna kwadratów odchyłeń kolejnych próbek od wartości oczekiwanej [33]. Wzór na obliczenie wartości ma postać

$$s^2 = \frac{1}{N} \sum_{n=1}^N (x_n - \mu)^2, \quad (3.5)$$

gdzie:

μ – jest wartością oczekiwaną sygnału.

Odchylenie standardowe

Odchylenie standardowe sygnału liczone jako pierwiastek ze średniej arytmetycznej kwadratów odchyleń kolejnych próbek od wartości oczekiwanej [33]. Wzór na obliczenie wartości ma postać

$$\sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \mu)^2}. \quad (3.6)$$

Długość obwiedni

Długość obwiedni (Wavelet Form) jest sumą zmian amplitud sygnału w kolejnych pomiarach [32–34]. Wzór na obliczenie wartości ma postać

$$x_{WF} = \sum_{n=2}^N |\Delta x_n|, \quad (3.7)$$

gdzie:

Δx_n – jest różnicą między n -tą próbką i poprzedzającą ją próbką $n - 1$.

Energia

Energia sygnału rozumiana jest jako suma kwadratów amplitud kolejnych próbek [35]. Wzór na obliczenie wartości ma postać

$$x_{EN} = \sum_{n=1}^N |x_n|^2. \quad (3.8)$$

3.1.2.2 Cechy częstotliwościowe

Dyskretna transformacja Fouriera

Dyskretna transformacja Fouriera jest funkcją odwzorowującą ciąg próbek sygnału $(x_0, x_2, x_3, \dots, x_{N-1})$ w ciąg harmoniczných $(A_0, A_2, \dots, A_{N-1})$. Funkcja przekształca sygnał z dziedziny czasu w dziedzinę częstotliwości [36, 37]. Przekształcenie zostaje przeprowadzone zgodnie ze wzorem

$$A_k = \sum_{n=0}^{N-1} x_n \omega_N^{-kn}, \quad (3.9)$$

$$\omega_N = e^{\frac{2\pi i}{N}}, \quad (3.10)$$

gdzie:

k – numer harmoniczných,

i – jednostka urojona,

e – wartość liczby Eulera.

Funkcja wykorzystuje operację iloczynu skalarnego badanego sygnału x_n i jądra przekształcenia. Jako jądro stosowane są funkcje sinusoidalne. Wynikiem przekształcenia jest Transformata Fouriera.

3.1.2.3 Cechy czasowo – częstotliwościowe

Krótkoczasowa transformacja Fouriera


Krótkoczasowa transformacja Fouriera jest funkcją przekształcającą sygnał z dziedziny czasu w dziedzinę częstotliwości z uwzględnieniem przedziałów czasowych. Za rozdzielczość w dziedzinie czasu odpowiada okno próbkujące. Najczęściej stosowane jest okno Hann'a i okno Gaussa (rys. 3.2) [31, 38–40]. Przekształcenie zostaje przeprowadzone zgodnie ze wzorem

$$X(m, k) = \sum_{n=0}^{N-1} x_n w_{n-m} \omega_N^{-kn}, \quad (3.11)$$

gdzie:

w_n – funkcja okna (rys 3.2),

m – przesunięcie okna w czasie.



Rysunek 3.2: Sygnały przykładowe okna Hanna (a) i Gaussa (b).

Spektrogram jest modulem wyniku krótkoczasowej transformacji Fouriera podniesionym do kwadratu zgodnie ze wzorem:

$$X_{SPEC}(m, \omega) = |X(m, \omega)|^2 \quad (3.12)$$


Przykładowy spektrogram sygnału elektromiograficznego został zaprezentowany na rysunku 3.3.

W przypadku krótkoczasowej transformacji Fouriera należy znaleźć kompromis pomiędzy rozdzielczością w dziedzinie czasu i w dziedzinie częstotliwości. Zwiększając rozdzielczość czasową poprzez skrócenie długości okna czasowego w_n zostaje zmniejszona rozdzielczość w dziedzinie częstotliwości. Zmniejszenie natomiast rozdzielczości w czasie, czyli wydłużenie funkcji okna, skutkuje utratą rozdzielczości w dziedzinie czasu i zwiększeniem w dziedzinie częstotliwości.

3.1.3 Procedury selekcji

Zgodnie ze schematem 3.1 selekcja cech jest jednym z etapów procesu rozpoznawania wzorców. Znajduje się pomiędzy etapem ekstrakcji i etapem klasyfikacji. Polega na usunięciu z wektora cech jego części [41–43], w wyniku czego otrzymywany jest podzbiór cech F' , taki że

$$|F| \geq |F'|, \quad (3.13)$$



Rysunek 3.3: Spektrogram wybranego sygnału elektromiograficznego

gdzie $|F|$ oznacza moc zbioru cech F .

Usunięcie odbywa się przy założeniu, że zbiór cech opisywany jest pewną funkcją kryterialną J . Selekcja polega na zoptymalizowaniu funkcji J :

$$F' = \arg \max(J(F)), \quad (3.14)$$

gdzie $\arg \max$ przyporządkowuje funkcji J zbiór argumentów, dla których osiąga ona maksimum. W postawionym zadaniu selekcji zbiorem argumentów jest zbiór cech należących do F' .

Dla metod selekcji będących filtrami, funkcja J maksymalizuje przyjęty współczynnik [44–46]. Dla metod należących do wrapperów, funkcja kryterialna maksymalizuje poprawną jakość przyporządkowania zbioru cech do jednej z klas [44–46].

Cechy szukane do usunięcia można podzielić na dwie grupy:

- nieistotne – takie, które nie są skorelowane z klasą, którą opisują,

- nadmiarowe – takie, które można wyliczyć z pozostałych cech. Ich usunięcie nie powoduje straty informacji opisującej klasę z powodu redundantnych danych.

Pozostały zbiór, po usunięciu z niego cech nieistotnych i nadmiarowych, tworzy zbiór cech istotnych, czyli takich które mają wpływ na wynik klasyfikacji i nie mogą być zastąpione przez inną cechę lub przez przekształcenia innych cech.

3.1.3.1 Problem wymiarowości

W procesie rozpoznawania wzorców problem wymiarowości rośnie wykładniczo dla rosnącego rozmiaru zbioru cech $|F|$. Praktyka pokazuje, że powyżej pewnej ilości wymiarów, skuteczność klasyfikacji zaczyna spadać zamiast rosnać [47]. Ponadto ze względu na naturę otaczającego świata, człowiek dobrze radzi sobie z wizualizacją i zrozumieniem danych w maksymalnie 3 wymiarach [48].

Redukcja wymiarowości może następować poprzez selekcję cech lub ich redukcję. Selekcja polega na wybieraniu cech z dostarczonego wektora. Redukcja natomiast skupia się na stworzeniu nowych cech na podstawie dostarczonego zbioru F . Rozwiązując problem wymiarowości należy wybrać jedno z dwóch dostępnych rozwiązań zmniejszających rozmiar wynikowego wektora cech F' :

- wybór podzbioru jedynie istotnych cech,
- przekształcenie oryginalnych zmiennych F w F' ,

w obydwu przypadkach celem jest otrzymanie takiego wektora F' , że $|F| \gg |F'|$.

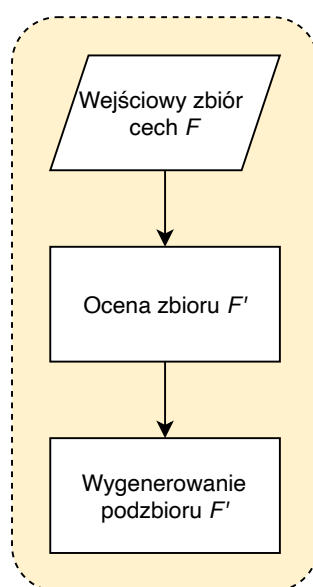
Dla rosnącej liczby wymiarów algorytmy analizujące odległość w wielowymiarowej przestrzeni przestają działać. Dzieje się tak z powodu malejącej różnicy między największą i najmniejszą odległością w badanej przestrzeni [49, 50] zgodnie ze wzorem dla liczby cech $|F|$ rosnącej do nieskończoności:

$$\lim_{|F| \rightarrow \infty} E \left(\frac{dist_{max}(d) - dist_{min}(d)}{dist_{min}(d)} \right) \rightarrow 0, \quad (3.15)$$

gdzie $dist()$ jest funkcją odległości. Z tego powodu algorytmy uczenia maszynowego korzystające z wyliczania dystansu w $|F|$ -wymiarowej przestrzeni pogarszają swoje własności poprawnej klasyfikacji.

3.1.3.2 Filtry

Filtry jest to grupa metod selekcji cech. Decyzja o wyborze podejmowana jest niezależnie od klasyfikatora (rys. 3.4) i odbywa się na podstawie wyliczonego współczynnika. Pomiędzy etapem klasyfikacji, a etapem selekcji nie zachodzi sprzężenie zwrotne. Otrzymany podzbiór cech F' nie jest zoptymalizowany pod kontem wykorzystywanego modelu [44–46, 51].



Rysunek 3.4: Schemat działania algorytmów należących do grupy filtrów [52]

Metryka Fishera

Współczynnik separacji dwóch klas. Im wektory cech reprezentujące klasy są dalej od siebie, tym pewniej da się odseparować od siebie badane klasy. [53] Metryka Fishera sprawdza, jak bardzo różni się od siebie badana i -ta cecha dla dwóch rozpatrywanych klas [54]:

$$v_i = \frac{(\sigma_{A,i} + \sigma_{B,i})^2}{s_{A,i}^2 + s_{B,i}^2}, \quad (3.16)$$

gdzie:

$\sigma_{A,i}$ – jest wartością średnią i -tej cechy z próbek należących do klasy A ,

$s_{A,i}^2$ – jest wartością wariancji i -tej cechy z próbek należących do klasy A .

Duża wartość metryki Fishera v_i oznacza, że wartości i -tej cechy dla dwóch badanych klas są od siebie odseparowane i cecha nadaje się do rozróżniania między klasami.

Mała wartość natomiast oznacza rozproszenie klas i potencjalną możliwość wystąpienia przemieszania danych między klasami. Rozróżnianie klas na podstawie takiej cechy może być zawodne.

Eliminacja po wariancji

Dla każdej cechy z wektora cech zostaje obliczona wartość wariancji zgodnie ze wzorem 3.5. Następnie wyliczone wartości zostają posortowane rosnąco, co daje wyniki ułożone od największej wariancji do najmniejszej. Chcąc otrzymać n -wymiarowy wektor cech, zostaje wyselekcjonowanych n pierwszych cech. Pozostałe dane zostają odrzucone do dalszego procesu rozpoznawania [55, 56]. Alternatywnie odrzucone zostają wszystkie cechy, dla których wartość wariancji jest mniejsza od założonego progu akceptacji.

Odrzucone zostają te cechy, dla których wartość wariancji jest najmniejsza w zbiorze. A więc te, które dla różnych pomiarów mają wartości bardzo zbliżone do siebie (lub takie same).

3.1.3.3 Wrappery

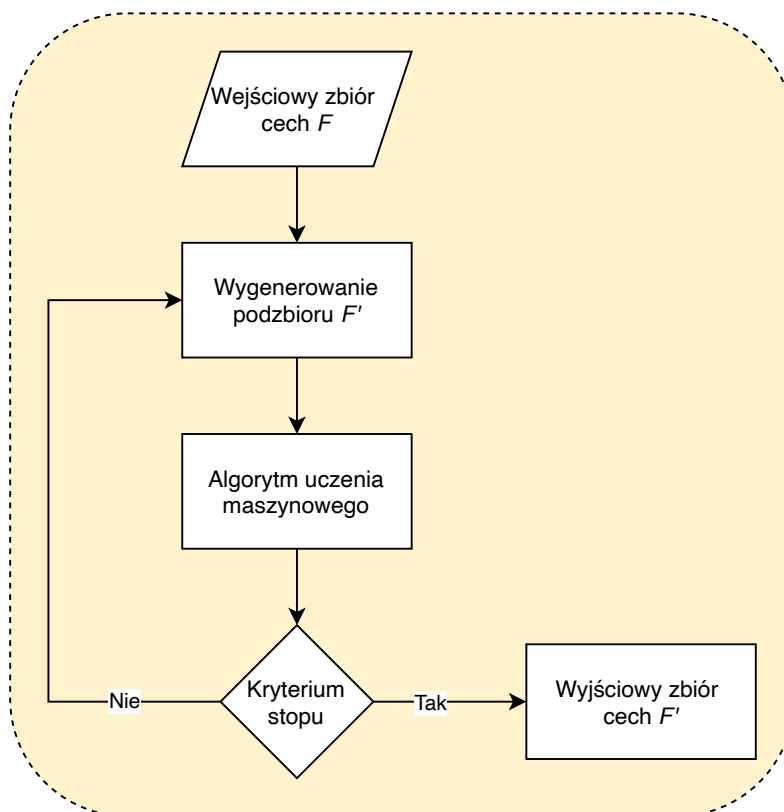
Grupa metod, gdzie zbiór cech F' wybierany jest przy pomocy algorytmu uczenia maszynowego. Dla problemu klasyfikacji najczęściej jest nim klasyfikator końcowy (rys. 3.5). Ocena wybranego podzbioru cech F' wykonywana jest przy pomocy modelu klasyfikatora, stąd wybrany podzbiór jest zoptymalizowany pod kątem wykorzystanego klasyfikatora [44–46, 51]. Algorytmy z grupy wrapperów, ze względu na testowanie wielu różnych podzbiorów cech, są wolne.

Sekwencyjna selekcja wsteczna

Algorytm selekcji polegający na sukcesywnym usuwaniu cech z wektora cech. Elementy usuwane są pojedynczo. W każdej iteracji wybierana jest ta cecha, której usunięcie maksymalnie poprawi (w szczególności minimalnie pogorszy) wynik klasyfikacji [57].

W przypadku sekwencyjnej selekcji w tył algorytm postępowania przedstawia się następująco:

1. Weź początkowy zbiór cech, taki że $F = \{f_1, \dots, f_R\}$.
2. Dla każdego elementu ze zbioru F wybierz jeden element.



Rysunek 3.5: Schemat działania algorytmów należących do grupy wrapperów [52]

3. Wytrenuj, a następnie przetestuj algorytm uczenia maszynowego J przy pomocy zbioru cech F .
4. Wybierz j -ty element, taki po usunięciu którego algorytm uczenia maszynowego dał najlepsze wyniki.
5. Usuń j -ty element ze zbioru F , $F = F \setminus \{f_j\}$
6. Sprawdź, czy warunek stopu został spełniony. Jeżeli tak, otrzymany zbiór cech spełnił zadany warunek i selekcja może zostać zakończona. W przeciwnym razie wróć do punktu 2.

Jeżeli liczność początkowego zbioru cech F jest duża oraz liczność wynikowego zbioru F' jest mała, bardziej opłacalnym algorytmem pod względem czasu wykonywania jest sekwencyjna selekcja w przód.

Sekwencyjna selekcja w przód

Analogiczny algorytm do sekwencyjnej selekcji wstecznej. W przypadku selekcji w przód algorytm sukcesywnie wybiera po jednej cesze z wejściowego zbioru F , aż do momentu kiedy wyjściowy zbiór F' zawiera zakładaną liczbę elementów. Kolejne cechy dodawane

są w taki sposób, że wybierana jest cecha, której dodanie jest lokalnie optymalne pod względem poprawności klasyfikacji.

3.1.4 Klasyfikatory

Ostatnim etapem procesu rozpoznawania jest klasyfikacja. Na podstawie zbioru cech F (rys. 3.1) i algorytmu uczenia maszynowego dokonywana jest decyzja przypisania zbioru cech do jednej ze wcześniej zdefiniowanych klas. Algorytm uczenia maszynowego nie posiada informacji o klasie, a decyzja podejmowana jest na podstawie wcześniej wytrenowanego modelu. Zadanie takie można zdefiniować jako odwzorowanie przestrzeni cech w przestrzeń klas, takich że

$$h : F \rightarrow C_i, \quad (3.17)$$

gdzie:

h – jest funkcją modelu klasyfikatora,

C_i – jest i -tą klasą.

W pierwszym etapie model klasyfikatora zostaje poddany procesowi uczenia. Zbiór danych uczących D (wzór 3.2) (wraz z informacją o przyporządkowaniu do konkretnej klasy) przekazywany jest do modelu klasyfikatora. Podejście takie nazywane jest uczeniem z nadzorem [58, 59].

Następnie, gotowy model klasyfikatora można poddać etapowi testowania. Na podstawie wektorów cech dokonywane jest wnioskowanie, w wyniku czego otrzymywana jest decyzja sterująca.

3.1.4.1 Klasyfikator K najbliższych sąsiadów

Algorytm K – najbliższych sąsiadów (k-NN) jest klasyfikatorem minimalno – odległościowym. Dla badanej próbki danych (zbioru cech) szukany jest pewien podzbiór S_k w przestrzeni S , taki że dla zbioru testowego \mathbf{F} należy wyznaczyć zbiór k najbliższych leżących punktów (sąsiadów) oznaczonych jako S_k , gdzie $S_k \subseteq S$ oraz

$$|S_k| = k. \quad (3.18)$$

Przestrzeń S generowana jest na etapie uczenia klasyfikatora knn przy pomocy par: zbiór cech, numer przyporządkowanej klasy (wzór 3.2). Dla próbki testowej F szukany jest taki zbiór najbliższych sąsiadów S_k [60], że

$$\forall F' \in S \setminus S_k : dist(F, F') \geq \max_{F'' \in S_k} dist(F, F''). \quad (3.19)$$

Dla każdego punktu F' w przestrzeni S z wyłączeniem przestrzeni S_k odległość między testowanym punktem F i punktem F' jest większa lub równa maksymalnej odległości pomiędzy punktem testowym F , a najodleglejszym od niego punktem z przestrzeni S najbliższych sąsiadów S_k .

Dla tak postawionego warunku każdy punkt w przestrzeni $D \setminus S_k$ jest co najmniej tak oddalony od punktu F , jak najdalszy punkt w S_k [61–63].

3.1.4.2 Maszyna wektorów nośnych

Algorytm maszyny wektorów nośnych (ang. *Support vector Machine*) jest algorytmem uczenia maszynowego. Działa na zasadzie istnienia przestrzeni decyzyjnej, która zostaje podzielona przy pomocy hiperpłaszczyzn oddzielających od siebie próbki należące do różnych klas [64, 65].

Algorytm podczas fazy uczenia minimalizuje funkcję błędu, taką że:

$$\Gamma(w) = arg \min_w \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i. \quad (3.20)$$

Poprzez minimalizację wartości $\|w\|$ zostaje zmaksymalizowana szerokość marginesu pomiędzy próbkami z różnych klas.

Dodatkowo muszą zostać spełnione warunki:

$$y_i(wF_i + b) \geq 1 - \xi_i, \quad (3.21)$$

gdzie:

w – jest wektorem współczynników,

C – jest stałą nazywaną *pojemnością*, która odpowiada za dopasowanie algorytmu pod względem dokładności i złożoności modelu,

ξ_i – jest parametrem kontrolującym źle rozpoznane przykłady oraz przyjmuje wartość nieujemną $\xi \geq 0$,

b – parametr określający położenie hiperpłaszczyzny,

N – jest licznością zbioru uczącego.

3.1.4.3 Naiwny klasyfikator Bayesa

Naiwny klasyfikator Bayesa jest klasyfikatorem opartym na metodzie probabilistycznej. Końcowa klasyfikacja dokonywana jest na podstawie prawdopodobieństwa a priori i a posteriori wystąpienia zdarzenia [66, 67].

Klasyfikator wykorzystuje twierdzenie Bayesa:

$$P(C_i|F) = \frac{P(F|C_i)P(C_i)}{P(F)}. \quad (3.22)$$

W równaniu 3.22 mianownik jest nieistotny pod kontem zadania klasyfikacji, ponieważ nie zależy od klasy C_i . Przyjmuje stałą wartość niezależnie od wartości C_i dla takiego samego F . Stąd wzór na wyliczenie prawdopodobieństwa przyjmuje postać

$$P(C_i|f_1, f_2, \dots, f_R) = P(f_1, f_2, \dots, f_R|C_i)P(C_i). \quad (3.23)$$

Obliczenie prawdopodobieństwa warunkowego wystąpienia C_i pod warunkiem F jest bardzo skomplikowanym zadaniem. Przyjmując założenie, że elementy ze zbioru F są od siebie statystycznie zadanie upraszcza się do wyliczenia iloczynu

$$P(f_1, f_2, \dots, f_R|C_i) = \prod_{k=1}^R P(f_k|C_i). \quad (3.24)$$

Po dalszym przekształceniu wzór 3.22 przyjmuje postać

$$P(C_i|F) = P(C_i) \prod_{k=1}^R P(f_k|C_i). \quad (3.25)$$

Przy założeniu, że dane są o rozkładzie normalnym wartość $P(f_k|C_i)$ można wyliczyć z rozkładu prawdopodobieństwa normalnego

$$P(f_k|C_i) = \frac{1}{\sigma_{kj}\sqrt{2\pi}} \exp\left(-\frac{(f_k - \mu_{kj})^2}{2\sigma_{kj}^2}\right), \quad (3.26)$$

gdzie:

μ_{kj} – jest wartością oczekiwaną k -tej zmiennej dla j -tej klasy.

Ostatecznie wzór na prawdopodobieństwo warunkowe zajścia zdarzenia C_i pod warunkiem wystąpienia F przyjmuje postać

$$P(C_i|F) = P(C_i) \prod_{k=1}^R \frac{1}{\sigma_{kj} \sqrt{2\pi}} \exp\left(-\frac{(f_k - \mu_{kj})^2}{2\sigma_{kj}^2}\right). \quad (3.27)$$

Klasyfikacja zostaje dokonana dla tej klasy C_i , dla której wartość prawdopodobieństwa warunkowego (wzór 3.27) przyjmuje największą wartość.

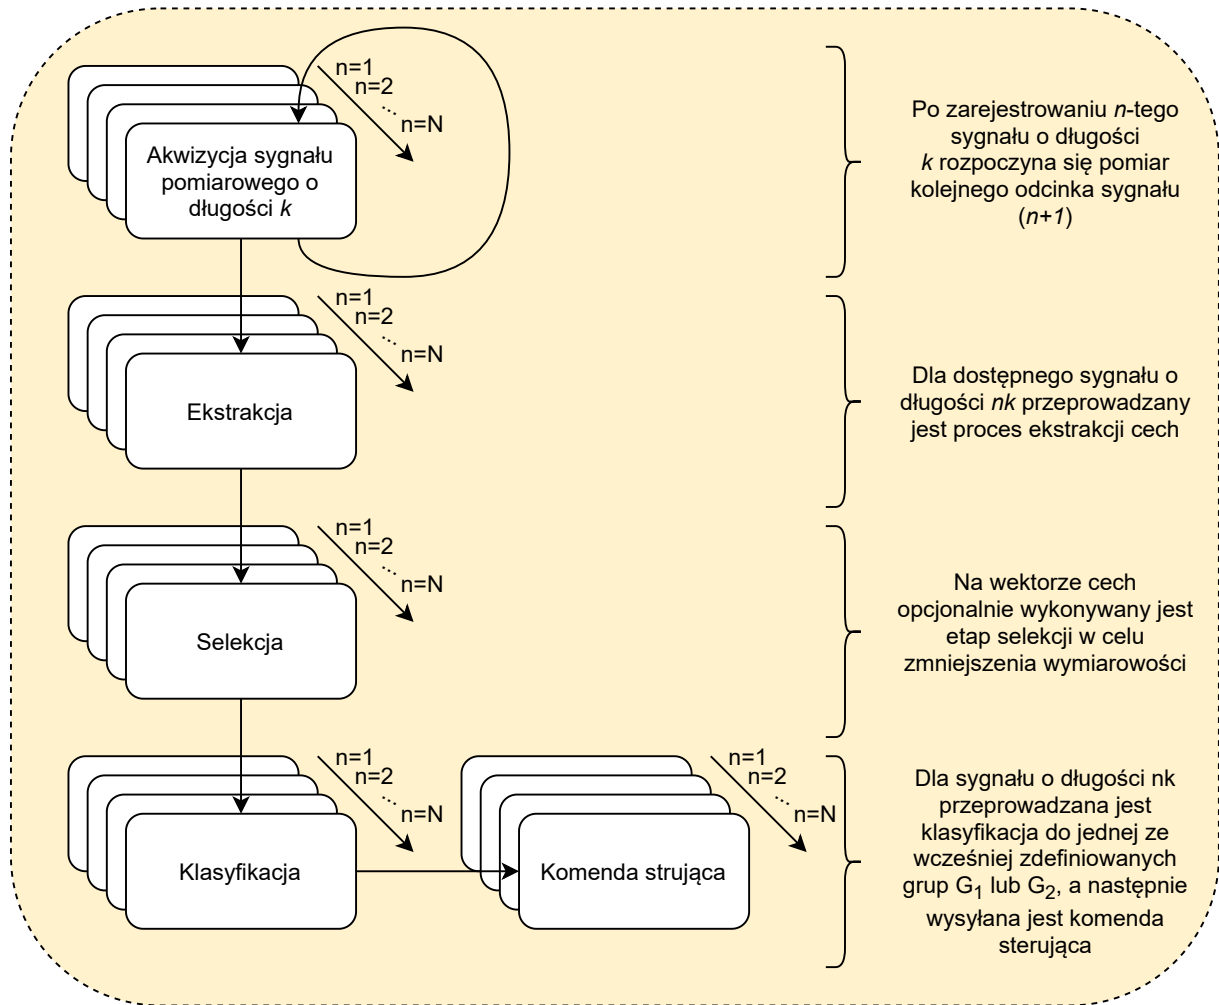
3.2 Podejście wieloetapowe

Idea rozpoznawania wieloetapowego w procesie etykietowania sygnałów elektromniograficznych dla potrzeb sterowania robotyczną protezą dłoni opiera się na założeniu, że wejściowy, surowy sygnał posiada użyteczne informacje już na początku swojego przebiegu czasowego. Nie ma więc potrzeby czekania na zakończenie pomiaru, aby rozpocząć proces przyporządkowywania sygnału do ruchu [68].

Klasyczne podejście zaprezentowane na diagramie 3.1 może więc zostać zrównoleżone poprzez jednoczesną akwizycję danych pomiarowych i poddawanie dostępnego już sygnału procesowi ekstrakcji, selekcji i klasyfikacji.

Proces taki został przedstawiony na schemacie 3.6. Po zarejestrowaniu sygnału o długości k przeprowadzony zostaje proces klasyfikacji ruchu. Jednocześnie etap rejestracji nadal trwa. Ponownie proces klasyfikacji zostaje wykonany dla sygnału o długości $2 \cdot k$, następnie $3 \cdot k$, aż do końca pomiaru. Sygnał zostaje zaklasyfikowany nie do jednej z klas końcowych C_i , ale do jednej z grup G_i , na które składają się klasy końcowe. Dzięki temu w początkowych fazach akwizycji sygnału możliwe jest rozpoczęcie działania algorytmów uczenia maszynowego przy ograniczonych danych pomiarowych. Pomimo iż nie jest znana intencja końcowej konfiguracji dłoni, to można już rozpocząć wstępny ruch robotycznej protezy [69].

Zadanie klasyfikacji wieloetapowej zostało zdefiniowane jako binarne drzewo decyzyjne [70, 71]. W węzłach niebędących liśćmi przyporządkowanie zostaje przeprowadzone do jednej z grup G_{i1} , lub G_{i2} , takich że



Rysunek 3.6: Diagram procesu sekwencyjnego rozpoznawania

$$\begin{cases} G_i \subseteq C \\ G_{i1} \cup G_{i2} = G_i \\ G_{i1} \cap G_{i2} = \emptyset \end{cases} \quad (3.28)$$

Binarne drzewo klasyfikacji można w takim wypadku opisać parą L_i , gdzie

$$L_i = (W_i, (L_{i,1}, L_{i,2})). \quad (3.29)$$

Dla drzewa binarnego L_i może przyjąć jedną z dwóch wartości:

- $L_i = (W_i, (L_{i,1}, L_{i,2}))$ – dla węzła niebędącego liściem,
- $L_i = (W_i, ())$ – dla liścia drzewa.

Węzeł W_i jest funkcją odwzorowującą zbiór cech F w zbiór klas G_i

$$W_i : F \rightarrow G_i \quad (3.30)$$

Końcowa klasyfikacja do jednej z klas należących do zbioru $C = \{C_1, C_2, \dots, C_i\}$ zostaje przeprowadzona w liściach drzewa.

3.2.1 Dane wejściowe

Podobnie jak w przypadku podejścia jednoetapowego (rozdział 3.1) jako dane wejściowe została wykorzystana baza pomiarowa opisana w rozdziale 4.3.3.1. Badaniu zostały poddane zarejestrowane sygnały elektromiograficzne.

3.2.2 Ekstrakcja cech

Algorytmy wykorzystane w procesie ekstrakcji cech dla klasyfikacji wieloetapowej zostały opisane w rozdziale 3.1.2.

3.2.3 Selekcja

W procesie klasyfikacji wieloetapowej etap selekcji cech został pominięty. W dalszych obliczeniach wykorzystywany jest wektor cech o pełnej długości.

3.2.4 Schemat decyzyjny

W procesie klasyfikacji wieloetapowej w każdym węźle drzewa decyzyjnego przeprowadzana jest niezależna klasyfikacja w celu podjęcia decyzji. W wyniku procesu zbiór klas ruchów dzielony jest na dwa rozłączne podzbiory o licznosci co najmniej 1. Podział klas odbywa się zgodnie z warunkami ustalonymi we wzorze 3.28.

W odróżnieniu od klasycznego podejścia do budowania drzewa decyzyjnego w procesie rozpoznawania obiektów [72, 73] drzewo decyzyjne dla rozpoznawania wieloetapowego tworzone jest z węzłów decyzyjnych dzielących zbiór klas. W każdym węźle wykorzystywany jest taki sam klasyfikator niezależnie od głębokości drzewa.

3.2.5 Opracowanie drzewa decyzyjnego

Drzewo decyzyjne budowane jest na podstawie jednej z dwóch opisanych w dalszej części strategii:

- przegląd zupełny,
- analiza statystyczna.

W każdym węźle przeprowadzany jest podział zbioru ruchów na dwa rozłączne podzbiory aż do momentu, kiedy wszystkie klasy znajdują się w liściach [72, 73]. Podział przeprowadzany jest zgodnie z przyjętą strategią. Dodatkowo drzewo opracowywane jest z wykorzystaniem tylko jednej strategii.

3.2.5.1 Przegląd zupełny

Opracowanie drzewa decyzyjnego poprzez przegląd zupełny jest przeprowadzany z pomocą algorytmu uczenia maszynowego. W każdym węźle drzewa niebędącym liściem grupa klas G_i dzielona jest na dwie podgrupy G_{i1} oraz G_{i2} . Podział zostaje przeprowadzony na wszystkie dostępne w danym węźle sposoby. Dla każdego podziału przeprowadzana zostaje klasyfikacja. Podział dla którego wartość klasyfikacji jest najlepsza zostaje wybrany do podziału w badanym węźle drzewa. Otrzymany wynik jest lokalnie optymalny pod względem poprawności klasyfikacji [74].

3.2.5.2 Analiza statystyczna

Opracowanie drzewa decyzyjnego poprzez analizę statystyki wykonywane jest przy pomocy informacji o odległościach między klasami należącymi do grupy G_i . Dla każdej klasy z grupy wyliczany zostaje wektor cech reprezentujący daną klasę, który jest uśrednieniem wektorów cech wszystkich pomiarów występujących w klasie [75]. Następnie między wyliczonymi reprezentantami liczone są statystyki:

- wartość minimalna odległość między klasami:

$$d_i^{min} = \min_{C_j \in G'_i} dist(C_i, C_j), \quad (3.31)$$

- wartość maksymalna odległość między klasami:

$$d_i^{max} = \max_{C_j \in G'_i} dist(C_i, C_j), \quad (3.32)$$

- średnia wartość odległości między klasami:

$$\bar{d}_i = \sum_{C_j \in G'_i} \frac{dist(C_i, C_j)}{|G'_i|}, \quad (3.33)$$

- odchylenie standardowe odległości między klasami:

$$d_i^{std} = \sqrt{\frac{1}{|G'_i| - 1} \sum_{C_j \in G'_i} (dist(C_i, C_j) - \bar{d}_i)^2}, \quad (3.34)$$

gdzie:

$$dist(C_i, C_j) = \sqrt{((C_i)_1 - (C_j)_1)^2 + ((C_i)_2 - (C_j)_2)^2 + \dots + ((C_i)_R - (C_j)_R)^2} \quad (3.35)$$

jest odległością euklidesową między reprezentantami klasy i -tej i j -tej [76], gdzie R jest liczbą cech w zbiorze oraz

$$G'_i = G_i \setminus \{C_i\}. \quad (3.36)$$

Podział klas z grupy G_i na G_{i1} oraz G_{i2} następuje poprzez analizę wyżej wspomnianych statystyk. Wyniki otrzymane dla każdego parametru z osobna zostają posortowane rosnąco. Następnie dla wartości minimalnej, maksymalnej i średniej przyporządkowywane są wartości rankingowe równe kolejnym liczbom porządkowym. Dla odchylenia standardowego wartości rankingowe przyporządkowywane są na odwrót. Im większa jest wartość odchylenia standardowego, tym mniejsza wartość rankingowa p_i .

Klasa, która zgromadziła największą wartość punktów rankingowych p_i łącznie, zostaje wybrana do grupy G_{i1} :

$$G_{i1} = G_{arg\ max_i p_i}. \quad (3.37)$$

Reszta klas zostaje dodana do G_{i2} :

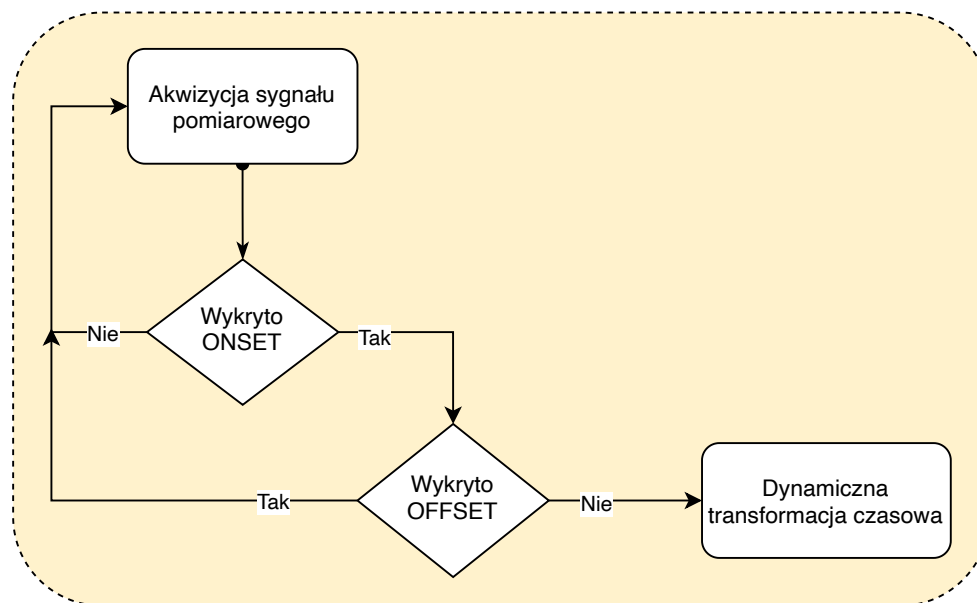
$$G_{i2} = G_i \setminus G_{i1}. \quad (3.38)$$

W przypadku, kiedy więcej niż jedna klasa zdobyła największą liczbę punktów, wszystkie zostają dodane do G_{i1} .

3.3 Dynamiczna transformacja czasowa

Dynamiczna transformacja czasowa (DTW) jest algorytmem służącym do badania podobieństwa między dwoma deterministycznymi przebiegami czasowymi o różnej długości. Metoda ta najczęściej wykorzystywana jest w procesie rozpoznawaniu mowy. Może znaleźć jednak zastosowania przy analizie podobieństwa sygnałów każdego rodzaju w dziedzinie czasu. Główną jego zaletą jest niwelowanie przesunięcia w czasie pomiędzy dwoma badanymi sygnałami. Dzięki temu moment rozpoczęcia pomiaru staje się nieistotny, a ważna jest jedynie informacja w nim zawarta. Dodatkowo algorytm jest odporny na długość wykonywania samego sygnału użytecznego. W przypadku analizy mowy, jest to szybkość mówienia. W przypadku badania sygnałów elektromiograficznych chodzi o szybkość wykonywania ruchu [77–80].

Rysunek 3.7 przedstawia schemat przetwarzania danych z zastosowaniem detekcji onestu oraz dynamiczną transformatą czasową. Algorytm DTW zastąpił etapy rozpoznawania takie jak ekstrakcja, selekcja i klasyfikacja.



Rysunek 3.7: Schemat przetwarzania z zastosowaniem DTW

W pierwszym kroku algorytmu obliczona zostaje macierz odległości $C_{N \times M}$ o wymiarach $N \times M$ pomiędzy wszystkimi parami punktów z dwóch badanych przebiegów X i Y , gdzie $X = \{x_1, x_2, x_3, \dots, x_N\}$ i $Y = \{y_1, y_2, y_3, \dots, y_M\}$ oraz

$$C_{N \times M} = \begin{bmatrix} \|x_1 - y_M\| & \|x_2 - y_M\| & \|x_3 - y_M\| & \dots & \|x_N - y_M\| \\ \|x_1 - y_{M-1}\| & \|x_2 - y_{M-1}\| & \|x_3 - y_{M-1}\| & \dots & \|x_N - y_{M-1}\| \\ \|x_1 - y_{M-2}\| & \|x_2 - y_{M-2}\| & \|x_3 - y_{M-2}\| & \dots & \|x_N - y_{M-2}\| \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \|x_1 - y_1\| & \|x_2 - y_1\| & \|x_3 - y_1\| & \dots & \|x_N - y_1\| \end{bmatrix}. \quad (3.39)$$

Do wyliczenia odległości między kolejnymi dwoma punktami może posłużyć odległość euklidesowa.

Algorytm obliczania macierzy odległości $C_{N \times M}$ dla DTW został zaprezentowany poniżej:

```

1 int obliczMacierzOdleglosci(X: array [1..N], Y: array [1..M]) {
2   C := array [0..N, 0..M]
3   for i := 0 to N
4     for j := 0 to M
5       C[i, j] := MAX_VALUE
6   C[0, 0] := 0
7   for i := 1 to N
8     for j := 1 to M
9       cost := dist(X[i], Y[j])
10      C[i, j] := cost + minimum(C[i-1, j ],
11                               C[i , j-1],
12                               C[i-1, j-1])
13   return C[n, m]
14 }
```

W kolejnym kroku zostaje wyznaczona ścieżka zgodności L przechodząca z punktu $C_{1,1}$ do punktu $C_{N,M}$ w taki sposób, żeby zminimalizować sumę wartości odległości kolejnych punktów pośrednich. Rysunek 3.8 przedstawia przykładową ścieżkę zgodności dla dwóch przykładowych sygnałów elektromiograficznych [77, 81].

Dla tak postawionego problemu należy wyznaczyć minimalną wartość ścieżki L przechodzącej z punktu $C_{1,1}$ do punktu $C_{N,M}$ zgodnie ze wzorem [80, 82]:

$$L(X, Y) = \min_W \left\{ \sum_{k=1}^K d_k, W = \langle w_1, w_2, \dots, w_K \rangle \right\}, \quad (3.40)$$

gdzie:

- W są kolejnymi punktami ścieżki L ,


- $w_k = (i, j)$ oraz i i j są kolejnymi indeksami macierzy C ,
- K jest długością ścieżki,
- d_k odpowiada odległości w punkcie $w_k = (i, j)$ macierzy C .

Ścieżka L rozpoczyna się w punkcie $w_1 = (1, 1)$ macierzy C oraz kończy w $w_K = (N, M)$.

Na kolejne punkty wyznaczonej ścieżki nałożone są ograniczenia:

$$w_k = (i, j), w_{k+1} = (i', j'), \quad (3.41)$$

$$i \leq i' \leq i + 1, j \leq j' \leq j + 1. \quad (3.42)$$




Rysunek 3.8: DTW - przykładowa ścieżka dla różnych sygnałów elektromiograficznych reprezentujących ten sam ruch

Rysunek 3.9 przedstawia dwa różne sygnały elektromiograficzne z odpowiadającymi sobie wartościami.

Dla dwóch idealnie dopasowanych sygnałów (dwa sygnały o identycznym przebiegu) ścieżka przebiegałaby dokładnie po przekątnej macierzy odległości $C_{N \times M}$, a wartość ścieżki zgodności wynosiłaby

$$L = 0. \quad (3.43)$$



Rysunek 3.9: DTW - porównanie dwóch różnych sygnałów elektromiograficznych reprezentujących ten sam ruch

W przeciwnym przypadku, dla sygnału o innym przebiegu niż sygnał odniesienia, wartość parametru zawsze spełnia warunek $L > 0$, a więc odległości kolejnych punktów sygnału są większe od 0.

3.4 Test Shapiro-Wilka

W celu zbadania normalności rozkładu otrzymanych wyników został wykorzystany test Shapiro-Wilka [83]. Dla testu zostają postawione dwie hipotezy:

H_0 : próba pochodzi z populacji o rozkładzie normalnym,

H_1 : próba nie pochodzi z populacji o rozkładzie normalnym.

Test jest przeprowadzany na poziomie istotności α . Dla tak dobranej wartości wyliczone zostaje odchylenie standardowe s^2 z badanej próby danych. Jeżeli liczba elementów w próbie jest parzysta, to parametr m przyjmuje wartość $m = \frac{n}{2}$, w przeciwnym razie $m = \frac{n-1}{2}$. Dla tak wyliczonej wartości m obliczona zostaje statystyka

$$W = \frac{b^2}{s^2}, \quad (3.44)$$

gdzie

$$b = \sum_{i=1}^m a_i (y_{n+1-i} - y_i) \quad (3.45)$$

oraz a_i zostaje odczytana z tabeli wartości współczynnika a_i dla testu Shapiro-Wilka.

Na podstawie obliczonej wartości statystyki W na zadanym poziomie istotności α oraz tabeli dla testu zostaje sprawdzona hipoteza H_0 .

3.5 Test t -studenta


W celu zbadania prawdopodobieństwa otrzymania średniej wartości wyników na zadanym poziomie został wykorzystany test t -Studenta dla jednej średniej [84, 85].

Dla testu zostają postawione dwie hipotezy:

H_0 : średnia wartość w populacji jest większa, bądź równa określonej wartości ($a \geq a_0$),

H_1 : średnia wartość w populacji jest mniejsza od określonej wartości ($a < a_0$).

$$t = \frac{\bar{y} - a_0}{s^2} \cdot \sqrt{n} \quad (3.46)$$



Rysunek 3.10: Rozkład t -studenta dla wybranych wartości liczności próby

Na podstawie wyliczonych parametrów i tablicy rozkładu t -Studenta sprawdzana jest hipoteza zerowa. Rozkład t -studenta dla różnych liczności próby został zaprezentowany na rysunku 3.10.

Rozdział 4

Badania eksperymentalne

4.1 Akwizycja danych

Akwizycja biosygnatów, a w szczególności sygnałów elektromiograficznych, może odbywać się w sposób inwazyjny i nieinwazyjny. Proces nieinwazyjnej rejestracji sygnału EMG nazywany jest elektromiografią powierzchniową (sEmg - surface electromyography). Polega na przymocowaniu elektrody pomiarowej do powierzchni skóry i badaniu wytworzonego na jej powierzchni potencjału elektrycznego. Ze względu na rejestrację sygnału w pewnej odległości od źródła i nakładanie się na siebie sygnałów (zjawisko superpozycji sygnału elektrycznego) elektromiograficznych z kolejnych kurczących się i rozkurczających mięśni występuje zaszumienie sygnału. W przypadku badania inwazyjnego stosuje się igłę pomiarową, która wprowadzana jest bezpośrednio do badanego mięśnia. Metoda ta najczęściej wykorzystywana jest w badaniach klinicznych. W pracy skupiono się na akwizycji nieinwazyjnej (sEmg). Pomiary wszystkich sygnałów zostały wykonane na powierzchni skóry.

4.2 Stanowisko badawcze

4.2.1 System do akwizycji danych pomiarowych


Kierując się przesłankami opisanymi w rozdziale 1.4, wykorzystano 16-to kanałowy system pomiarowy do rejestracji biosygnatów zaprojektowany na Politechnice Wrocławskiej, jako stanowisko do badania sygnałów elektromiograficznych i mechanomiograficznych (rys. 4.1). System ten obejmuje:

- 8 zintegrowanych sond pomiarowych, umożliwiających jednoczesną rejestrację w 8 punktach zarówno sygnałów elektromiograficznych jak i mechanomiograficznych,
- 16-to kanałowy system filtrująco-wzmacniający (8 kanałów dla EMG i 8 kanałów dla MMG),
- kartę przetworników analogowo-cyfrowych PCIE-1816 - firmy Advantech.



Rysunek 4.1: System pomiarowy zaprojektowany na Politechnice Wrocławskiej [28]

Szczegóły techniczne opracowanego układu pomiarowego zostały opisane w pozycji [86]. Każda sonda zawiera dwie metalowe elektrody paskowe i połączony z nimi bezpośrednio różnicowy wzmacniacz wstępny toru EMG oraz mikrofon elektretowy zbierający sygnały MMG. Te podzespoły zostały zintegrowane w obudowie (rys. 4.2a i 4.2b).



(a) od strony elektrod i komory akustycznej

(b) widok wnętrza ze wzmacniaczem

Rysunek 4.2: Widok sensora zespolonego [28, 86]

4.2.2 Opaska The Myo

Drugie zaproponowane stanowisko pomiarowe składa się z opaski *The Myo* (rys. 4.3). Jest to urządzenie komercyjne, stworzone przez firmę *Thalmic Labs*. W odróżnieniu od skomplikowanego systemu pomiarowego z poprzedniego rozdziału, prezentowany system składa się wyłącznie z samej opaski pomiarowej i dedykowanego adaptera bluetooth.

Opaska zbudowana jest z ośmiu elektrod pomiarowych zamontowanych na pierścieniu, w równej odległości od siebie. Każda z nich próbkuje z częstotliwością 200Hz . Dodatkowo opaska wyposażona jest w akcelerometr i żyroskop. Całość komunikuje się z systemem docelowym poprzez protokół bluetooth 4.0. Urządzenie posiada własne zasilanie [87].

Zamontowane elektrody na opasce zapewniają powtarzalność warunków pomiarowych. Przy założeniu, że opaska każdorazowo zakładana jest na tej samej wysokości przedramienia, położenie elektrod między badaniami nie różni się od siebie w zauważalny sposób. Wiąże się to jednak z pewnymi ograniczeniami. Stałe umiejscowienie sensorów na opasce zawęża pole akwizycji sygnału do małego wycinka powierzchni przedramienia. Pokrycie dodatkowych mięśni sensorami wymaga fuzji większej liczby opasek. W przypadku pominięcia poszczególnych kanałów w procesie selekcji cech, nie ma możliwości ponownego użycia niemiarodajnych – pomijanych kanałów.



Rysunek 4.3: Opaska The Myo [88]

Opaska pomiarowa jest narzędziem znajdującym szerokie zastosowanie w wielu dziedzinach. Począwszy od prostego sterowania aplikacjami komputerowymi, a skończywszy na manipulowaniu złożonymi systemami protetycznymi. Ze względu na własne zasilanie i niewielkie rozmiary jest w pełni mobilnym systemem pomiarowym. Może zostać wykorzystywana nie tylko podczas badań w laboratorium, ale również jako element większego systemu protetycznego [89–91].

4.3 Opis eksperymentu pomiarowego

Baza danych pomiarowych jest wynikiem pierwszego etapu procesu rozpoznawania biosygnali – akwizycji sygnału. Odpowiednia metodyka badania jest niezwykle istotna. Wpływa na jakość rejestrowanego sygnału, jak również na dokładność i powtarzalność pomiarów.

W pracach badawczych często spotykane rozwiązanie (rys. 4.4) zawiera 5 klas ruchów: ręka w stanie spoczynku, chwyt szczypcowy, chwyt mocy, chwyt boczny i otwarta ręka [27].



Rysunek 4.4: Klasyczny zestaw ruchów [92]

O ile stosowany zestaw zawiera podstawowe typy wykonywanych ruchów, to nadal jest niekompletny. Ponadto w zależności od autorów, dane pomiarowe mogą się od siebie różnić w sposób diametralny. Mogą na to wpływać takie parametry badania pomiarowego jak:

- liczba kanałów pomiarowych,
- modalność (rodzaj) badanego sygnału (sygnał elektromiograficzny, sygnał mechanomiograficzny),
- długość trwania pomiaru,
- częstotliwość próbkowania,
- umiejscowienie elektrod pomiarowych.

W konsekwencji przeprowadzenie takiego samego doświadczenia na dwóch różnych zestawach pomiarowych może dać zupełnie różne wyniki.

Zaproponowane zestawy danych pomiarowych zawierają dokładny opis protokołu wykonywania pomiaru i parametrów zmierzonego sygnału. Zarejestrowane dane są ogólnodostępne, a ponadto dzięki udostępnieniu protokołu pomiarowego doświadczenie może zostać odtworzone w takich samych warunkach.


4.3.1 Baza sygnałów EMG i MMG

4.3.2 Opis zasobu

Przedstawiony zestaw danych zawiera sygnały elektromiograficzne (EMG) i mechanomiograficzne (MMG) pobrane z mięśni przedramienia dorosłego człowieka. Akwizycja sygnału przeprowadzona została w sposób nieinwazyjny. Sam sygnał pomimo tego, że powstał w komórkach mięśniowych, został zarejestrowany na powierzchni skóry.

Rozmieszczenie czujników zaprezentowano na rysunku 4.5. Przy wyborze umiejscowienia elektrod kierowano się przede wszystkim potrzebą uzyskania dobrej powtarzalności. Elektrody są ułożone w dwóch rzędach (wewnętrzna/górna i zewnętrzna/dolna strona przedramienia) po 4 elektrody w rzędzie, w taki sposób, aby tworzyły linię prostą biegnącą od kciuka (czujnik 1) do łokcia (czujnik 4) i od małego palca (czujnik 5) do łokcia.

Pojedynczy czujnik wykorzystany do rejestracji sygnału jest fuzją dwóch modalności EMG – potencjał elektryczny z mięśnia i MMG – sygnał akustyczny powstający podczas skurczania i rozkurczania włókien mięśniowych.



(a) Zewnętrzna strona przedramienia

(b) Wewnętrzna strona przedramienia

Rysunek 4.5: Rozmieszczenie elektrod na przedramieniu [28]

Układ czujników został również zaplanowany w taki sposób, aby czujniki uwzględniały główne grupy mięśniowe i aby rejestrowany sygnał był w miarę możliwości różnorodny – zarejestrowany w różnych partiach przedramienia. W tym celu została wykorzystana wiedza z rozdziału 1.3 o budowie anatomicznej przedramienia dorosłego człowieka.

4.3.3 Metodyka prowadzenia pomiarów

Pomiary zostały przeprowadzone zgodnie z przyjętym wcześniej protokołem badań i w obecności osoby monitorującej poprawność wykonanego ruchu. Po weryfikacji pomiar był akceptowany lub w przypadku, kiedy nie spełniał wymagań zostawał odrzucany. W ten sposób do bazy danych trafiły jedynie takie dane, które spełniały wymagania jakościowe

autorów. Błędne zostały nieodwracalnie skasowane. Do badań zostało wykorzystanych 11 klas (rys. 4.6).

Parametry pojedynczego pomiaru:

Czas trwania:	2s
Częstotliwość próbkowania:	1000Hz
Liczba próbek na pomiar:	2000
Liczba kanałów:	16 (8 EMG + 8 MMG)

Łącznie z jednego pomiaru, na który składa się 16 kanałów, zostało otrzymanych 32000 próbek.

4.3.3.1 Opis ruchów

Poniżej zaprezentowana została pełna lista klas ruchów zawartych w bazie. Graficzna ilustracja ruchu została przedstawiona na rysunku 4.6. Poszczególne nazwy ruchów odpowiadają chwytanemu przedmiotowi:

C_1 – Ruch angażujący wszystkie palce dłoni. Przy ich pomocy chwytny jest podłużny owalny przedmiot. Kontakt z przedmiotem mają kciuk, palec wskazujący i palec środkowy.

C_2 – Ruch angażujący palec wskazujący i kciuk. Chwytny zostaje niewielki przedmiot.

C_3 – Ruch angażujący wszystkie palce dłoni do chwytania małego przedmiotu. Kciuk i palec wskazujący zostają ułożone podobnie, jak w przypadku ruchu C_2 .

C_4 – Ruch angażujący wszystkie palce dłoni. Chwytny zostaje podłużny przedmiot o szerokości zbliżonej do szklanki.

C_5 – Ruch angażujący wszystkie palce dłoni. Chwytnym przedmiotem jest ucho od kubka

C_6 – Ruch angażujący wszystkie palce dłoni. Chwytny jest przedmiot odpowiadający budowie np. rączkę czajnika.

C_7 – Ruch angażujący wszystkie palce dłoni. Chwytnym przedmiotem jest karta np. płatnicza. Przedmiot chwytny jest przy pomocy kciuka i palca wskazującego. Pozostałe palce zginane są niezależnie od chwytanego przedmiotu.

C_8 – Ruch angażujący wszystkie palce. Chwytanym przedmiotem jest telefon komórkowy. W pierwszej fazie ruchu przedmiot jest chwytny, w drugiej dłoń wykonuje ruch rotacyjny.

C_9 – Ruch angażujący wszystkie palce. Chwytanym przedmiotem jest myszka komputerowa.

C_{10} – Ruch angażujący wszystkie palce. Chwytanym przedmiotem jest telefon komórkowy.

C_{11} – Ruch angażujący wszystkie palce dłoni. Chwytny jest przedmiot odpowiadający budowie np. rączkę od walizki.

 C_1  C_2  C_3  C_4

 C_5  C_6  C_7  C_8  C_9  C_{10}

 C_{11}

Rysunek 4.6: Chwyty dla których został przeprowadzony eksperyment [28, 86]

Wszystkie powtórzenia ruchów zostały wykonane przy ustalonym ułożeniu przedramienia. W celu uniknięcia dodatkowych zakłóceń i wyeliminowania sygnałów wynikających z ruchów translacyjnych przedramię na czas badań zostało oparte o biurko i nieruchomo trzymane w takiej pozycji.

4.3.3.2 Organizacja bazy danych

Baza danych została zaprojektowana w taki sposób, aby wszystkie dane pomiarowe zarejestrowane dla jednego użytkownika znajdowały się w jednym pliku z rozszerzeniem **.mat* np. *dane.mat*. Rozmiar takiego pliku to około 400 MB. Po wgraniu pliku do odpowiedniego środowiska (np. *Matlab*, *Octave*, *Python*) zostaje wczytana 4 wymiarowa macierz danych o wymiarach 11 na 200 na 16 na 2000. Jej wymiary oznaczają kolejno: klasa ruchu, pomiar, kanał, próbka:

11 klas ruchów,

200 powtórzeń każdego ruchu,

16 kanałów (8 EMG, 8 MMG),

2000 próbek na pomiar.

Parzyste numery kanałów zawierają zarejestrowany sygnał mechaniczny MMG. Nieparzyste natomiast zostały przyporządkowane kolejnym kanałom sygnału EMG.

W konsekwencji chcąc pobrać cały pierwszy pomiar z drugiego kanału dla klasy ruchu nr 3 należy odczytać następujący element z tablicy: $dane(3,1,2,:)$. Natomiast w

Tabela. 4.1: Przyporządkowanie modalności i kanałów do sondy pomiarowej

Sonda	Kanał	Rodzaj modalności
I	I	EMG
	II	MMG
II	III	EMG
	IV	MMG
III	V	EMG
	VI	MMG
IV	VII	EMG
	VIII	MMG
V	IX	EMG
	X	MMG
VI	XI	EMG
	XII	MMG
VII	XIII	EMG
	XIV	MMG
VIII	XV	EMG
	XVI	MMG

celu pobrania ostatniej próbki z powyższego pomiaru należy odnieść się do elementu *dane(3,1,2,2000)*.


4.3.3.3 Dostępność

Badanie i poprawa jakości rozpoznawania sygnałów elektromiograficznych i mechanomiograficznych jest procesem niezwykle złożonym. Zastosowanie tej samej bazy danych zapewnia stałe odniesienie dla zmiennych parametrów procesu. Opisany zbiór pomiarowy został udostępniony w ramach projektu AZON [93]. Dane umieszczone tam są ogólnodostępne do pobrania.

4.3.4 Baza sygnałów EMG, MMG i postury dłoni

Kolejnym etapem rozwoju bazy danych z biosygnałami z powierzchni przedramienia było dodanie informacji o posturze palców dłoni. W tym celu wykorzystano rękawicę pomiarową z 11 czujnikami zgięcia (rys. 4.7). Zostały one umiejscowione po 2 na każdym palcu i jeden na śródreżcu dłoni. Rękawica pomiarowa jest dodatkowym modulem dołączanym do systemu do akwizycji sygnałów EMG i MMG.

Metodyka prowadzenia pomiarów i lista ruchów pozostały niezmiennione. Z powodu dodatkowej informacji z czujników zgięcia została zmodyfikowana organizacja bazy



Rysunek 4.7: Rękawica pomiarowa z czujnikami zgięcia

danych. Lista kanałów została rozszerzona o dodatkowe informacje z czujników zgięcia i czujników nacisku.

4.4 Wyznaczanie współczynnika algorytmu kNN

4.4.1 Założenia

Doświadczenie przeprowadzone zostanie dla wybranych metod ekstrakcji cech, takich jak

- Średnia kwadratowa – RMS,
- Średnia wartość absolutna – MAV,
- Wariancja – VAR,
- Odchylenie standardowe – STD,
- Energia – EN,
- Długość obwiedni – WFL.

Podczas doświadczenia zostanie wykorzystany zestaw danych pomiarowych opisany w rozdziale 4.3.1. Zbiór danych, to baza sygnałów elektromiograficznych.

4.4.2 Cel

Celem doświadczenia jest wyznaczenie wartości parametru k dla algorytmu k – najbliższych sąsiadów dla cech pozyskanych z sygnałów elektromiograficznych.

Ponadto dla otrzymanego parametru k zostanie zbadane, dla jakiej metody pozyskiwania cech wartość poprawnej klasyfikacji jest największa.

4.4.3 Przebieg


Badanie zostało przeprowadzone dla czasowych metod ekstrakcji cech z pominięciem etapu selekcji.

Otrzymane wyniki zostały przedstawione na wykresie 4.8. Wartość parametru k (liczba sąsiadów) została zbadana dla wartości od 1 do 100. Wartość *accuracy* została obliczona w następujący sposób:

$$accuracy = \frac{\text{liczba poprawnie sklasyfikowanych próbek}}{\text{całkowita liczba próbek}}. \quad (4.1)$$

Minimalna wartość parametru *accuracy* to 0 dla sytuacji, kiedy wszystkie pomiary zostały błędnie sklasyfikowane. Maksymalna wartość to 1, kiedy wszystkie próbki zostały poprawnie rozpoznane.

Prezentowane wyniki zostały otrzymane dla 5-cio krotnego sprawdzianu krzyżowego.



Rysunek 4.8: Dokładność rozpoznawania w zależności od wartości parametru k dla algorytmu kNN

4.4.4 Dyskusja

Otrzymane wyniki zamieszczone na rysunku 4.8 pokazują, że średnia poprawna wartość rozpoznawania jest największa dla parametru k równego 10. Wartości zostały otrzymane dla walidacji krzyżowej z 5-cio krotnym powtórzeniem

Zgodnie z otrzymanymi danymi najlepiej sprawował się parametr średniej wartości absolutnej (MAV) spośród przebadanych, czasowych metod pozyskiwania cech.

W celu zbadania poprawności otrzymanych wyników został wykorzystany test studenta (rozdział 3.5). Dla k o wartości 10 zostało wykonanych 30 niezależnych badań dla losowo wybranego zbioru uczącego i zbioru testującego. Badanie statystyczne zostało przeprowadzone dla algorytmu średniej wartości absolutnej.

Dla testu studenta zostały postawione dwie hipotezy:

H_0 : średnia wartość rozpoznawania a_0 dla $k = 10$ jest większa, bądź równa 0.75 ($a \geq a_0$),

H_1 : średnia wartość rozpoznawania a_0 dla $k = 10$ jest mniejsza od 0.75 ($a < a_0$).

Dla $n = 30$ pomiarów z losowo wybranym zbiorem testowym i zbiorem uczącym wartość parametru t statystyki testu studenta wynosi

$$t = \frac{\bar{y} - a_0}{s^2} \cdot \sqrt{n} = 7.747, \quad (4.2)$$

gdzie rozmiary zbioru testowego i zbioru uczącego wynosiły odpowiednio 0.2 i 0.8 liczości pełnego zbioru. Podział taki został zastosowany ze względu na użytą wcześniej walidację krzyżową w przypadku której stosunek liczby próbek uczących do próbek testujących wynosił również 0.25. Wartość średnia z pomiarów wyniosła $\bar{y} = 0.76$ oraz odchylenie standardowe $s^2 = 0.01$.

Dla wyliczonych parametrów hipoteza H_0 została potwierdzona na poziomie istotności równym 0.01.

4.5 Klasyczny proces rozpoznawania

4.5.1 Założenia

Doświadczenie przeprowadzone zostanie dla wybranych algorytmów ekstrakcji, selekcji i klasyfikacji cech.

Metody ekstrakcji:

- średnia kwadratowa,
- średnia wartość absolutna,
- wariancja,
- odchylenie standardowe,
- energia,
- długość obwiedni,
- szybka transformacja Fouriera,
- krótkoczasowa transformacja Fouriera,
- zbiór cech powstały na skutek konkatenacji zbiorów otrzymanych ze wszystkich powyższych metod.

Metody selekcji:

- metryka Fishera,
- eliminacja po wariancji,
- sekwencyjna selekcja wsteczna.

Metody klasyfikacji:

- k najbliższych sąsiadów,
- maszyna wektorów nośnych,
- naiwny klasyfikator Bayesa.

Badanie zostanie przeprowadzone dla połączenia każdej metody ekstrakcji z każdą metodą selekcji oraz każdą metodą klasyfikacji, jak również z pominięciem etapu selekcji cech.

Podczas doświadczenia zostanie wykorzystany zestaw danych pomiarowych opisany w rozdziale 4.3.1. Baza zawiera 11 klas ruchów. Dla każdego ruchu zostało wykonanych po 200 pomiarów. Na każdy pomiar składają się dane z 8 kanałów: 8 EMG.

4.5.2 Cel

Celem doświadczenia jest zbadanie poprawności rozpoznawania dla wybranych kombinacji algorytmów ekstrakcji, selekcji i klasyfikacji cech w klasycznym procesie przyporządkowywania wzorców (rys. 3.1) oraz wytypowanie optymalnego zestawu pod względem poziomu poprawności rozpoznawania.

4.5.3 Przebieg

Wszystkie wyniki zostały otrzymane przy pomocy 5-cio krotnego sprawdzianu krzyżowego.

W pierwszej kolejności została zbadana dokładność rozpoznawania dla wektora cech uzyskanego z pełnej długości dwusekundowego sygnału. W badaniu został pominięty etap selekcji cech. Wyniki dla wybranych algorytmów zostały przedstawione w tabeli 4.2.

Prezentowane wyniki zostały otrzymane dla 5-cio krotnego sprawdzianu krzyżowego. Przedstawione dane zawierają minimalną otrzymaną wartość poprawnej klasyfikacji, maksymalną i średnią.

Tabela. 4.2: Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji

Klasyfikacja	RMS	MAV	VAR	STD	EN	WFL	FFT	STFT	ALL
Wartość Średnia									
10-NN	0.71	0.77	0.65	0.71	0.66	0.71	0.89	0.91	0.87
SVM	0.40	0.43	0.32	0.39	0.32	0.38	0.51	0.75	0.64
Naiwny klas. Bayesa	0.60	0.65	0.52	0.59	0.53	0.56	0.72	0.87	0.86
Wartość minimalna									
10-NN	0.69	0.73	0.62	0.68	0.63	0.68	0.87	0.87	0.84
SVM	0.30	0.40	0.23	0.29	0.22	0.31	0.41	0.66	0.56
Naiwny klas. Bayesa	0.55	0.62	0.46	0.54	0.45	0.50	0.66	0.79	0.76
Wartość maksymalna									
10-NN	0.74	0.79	0.70	0.74	0.69	0.74	0.93	0.94	0.89
SVM	0.50	0.47	0.41	0.49	0.41	0.43	0.62	0.86	0.72
Naiwny klas. Bayesa	0.64	0.67	0.57	0.63	0.58	0.60	0.76	0.90	0.90

W kolejnym kroku został zbadany wpływ zastosowania etapu selekcji na poprawność rozpoznawania. Pierwsza metoda jaka została wykorzystana, to sekwencyjna selekcja wsteczna. W tabeli 4.3 zostały zaprezentowane wyniki dla selekcji ograniczającej wymiarowość zbioru cech F do siedmiu elementów dla każdej metody ekstrakcji z osobna oraz dla badania ze zbiorem cech powstałym z połączenia wszystkich metod razem.

Tabela. 4.3: Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji oraz metodą sekwencyjnej selekcji wstecznej dla 7 cech

Klasyfikacja	RMS	MAV	VAR	STD	EN	WFL	FFT	STFT	ALL
Wartość Średnia									
10-NN	0.72	0.77	0.66	0.72	0.66	0.69	0.37	0.34	0.79
SVM	0.40	0.43	0.33	0.38	0.33	0.41	0.29	0.27	0.46
Naiwny klas. Bayesa	0.59	0.64	0.51	0.58	0.52	0.57	0.37	0.38	0.68
Wartość minimalna									
10-NN	0.69	0.73	0.63	0.69	0.62	0.66	0.31	0.32	0.77
SVM	0.37	0.37	0.27	0.29	0.28	0.34	0.24	0.23	0.41
Naiwny klas. Bayesa	0.53	0.62	0.46	0.53	0.46	0.53	0.34	0.34	0.64
Wartość maksymalna									
10-NN	0.75	0.81	0.70	0.74	0.68	0.72	0.43	0.35	0.81
SVM	0.46	0.49	0.40	0.46	0.41	0.45	0.34	0.32	0.53
Naiwny klas. Bayesa	0.64	0.66	0.56	0.63	0.56	0.59	0.43	0.40	0.71

Następnie został zbadany wpływ metody selekcji, jaką jest metryka Fishera na poprawność rozpoznawania. Podobnie jak w przypadku sekwencyjnej selekcji wstecznej metryka Fishera ograniczyła zbiór cech dla każdego z przypadków do siedmiu. Otrzymane wyniki zostały zaprezentowane w tabeli 4.4.

Tabela. 4.4: Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji oraz współczynnikiem Fishera dla 7 cech

Klasyfikacja	RMS	MAV	VAR	STD	EN	WFL	FFT	STFT	ALL
Wartość Średnia									
10-NN	0.69	0.75	0.66	0.69	0.65	0.69	0.21	0.14	0.17
SVM	0.37	0.37	0.29	0.39	0.29	0.35	0.17	0.13	0.13
Naiwny klas. Bayesa	0.51	0.54	0.49	0.56	0.50	0.47	0.27	0.18	0.19
Wartość minimalna									
10-NN	0.68	0.70	0.63	0.67	0.63	0.67	0.18	0.11	0.15
SVM	0.32	0.33	0.23	0.30	0.23	0.31	0.13	0.11	0.10
Naiwny klas. Bayesa	0.47	0.45	0.42	0.51	0.43	0.44	0.24	0.15	0.15
Wartość maksymalna									
10-NN	0.72	0.79	0.70	0.71	0.70	0.72	0.22	0.16	0.20
SVM	0.45	0.41	0.35	0.48	0.36	0.40	0.21	0.16	0.14
Naiwny klas. Bayesa	0.53	0.60	0.53	0.60	0.54	0.51	0.30	0.21	0.25

W tabeli 4.5 zostały przedstawione wyniki dla metod ekstrakcji i klasyfikacji oraz eliminacji po wariancji jako metody selekcji cech. Warunkiem końcowym dla algorytmu selekcji było wyznaczenie 7 cech o największej wariancji.

Tabela. 4.5: Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji oraz eliminacją po wariancji dla 7 cech

Klasyfikacja	RMS	MAV	VAR	STD	EN	WFL	FFT	STFT	ALL
Wartość Średnia									
10-NN	0.69	0.73	0.65	0.69	0.65	0.69	0.31	0.25	0.58
SVM	0.39	0.41	0.32	0.39	0.32	0.37	0.25	0.17	0.28
Naiwny klas. Bayesa	0.56	0.60	0.50	0.56	0.50	0.55	0.32	0.26	0.37
Wartość minimalna									
10-NN	0.67	0.70	0.61	0.67	0.61	0.67	0.28	0.23	0.56
SVM	0.31	0.37	0.23	0.30	0.22	0.28	0.23	0.16	0.24
Naiwny klas. Bayesa	0.51	0.58	0.44	0.51	0.43	0.49	0.24	0.22	0.34
Wartość maksymalna									
10-NN	0.71	0.78	0.68	0.71	0.68	0.71	0.33	0.28	0.61
SVM	0.48	0.46	0.40	0.48	0.40	0.43	0.31	0.18	0.32
Naiwny klas. Bayesa	0.60	0.61	0.55	0.60	0.55	0.59	0.36	0.28	0.43

4.5.4 Dyskusja

Badanie miało na celu wyznaczenie najlepszego zestawu metod i algorytmów ekstrakcji, selekcji i klasyfikacji na potrzeby rozpoznawania intencji ruchu.

Zgodnie z przeprowadzonym badaniem spośród wszystkich zbadanych metod najlepsza okazała się kombinacja krótkoczasowa transformacja Fouriera jako metoda ekstrakcji cech

i 10-NN jako model klasyfikatora. Wynik został otrzymany z pominięciem etapu selekcji i jego średnia wartość wynosi 0.91. Dla tego samego zestawu metod najgorszy otrzymany wynik to 0.87, a najlepszy 0.94 (tab. 4.2). Wartości zostały otrzymane dla walidacji krzyżowej z 5-cio krotnym powtórzeniem.

W przypadku czasowych metod pozyskiwania cech liczność zbioru przed etapem selekcji wynosi 8. Najlepszy wynik, jaki udało się uzyskać dla takiej liczności zbioru cech to średnio 0.77 dla średniej wartości absolutnej (MAV) i 10-NN, gdzie wartość minimalna wyniosła 0.73, a wartość maksymalna 0.79 (tab. 4.2).

Ze względu na licznosc zbioru cech otrzymanych z metod czasowych, która wynosi 8 elementów, etap selekcji został przeprowadzony w taki sposób, żeby uzyskać wynikowy zbiór cech o licznosci 7.

Wyniki z sekwencyjnej selekcji wstecznej zostały przedstawione w tabeli 4.3. Najlepszy wynik, jaki został uzyskany dla wartości średniej to 0.77 dla średniej wartości absolutnej, gdzie wartość minimalna wyniosła 0.73, a wartość maksymalna 0.81. Algorytm sekwencyjnej selekcji wstecznej jest bardzo czasochłonną metodą pozyskiwania zbioru cech wynikowych.

Kolejną metodą selekcji, jaka została przebadana, jest metryka Fishera należąca do grupy filtrów. Podobnie jak w przypadku sekwencyjnej selekcji wstecznej, również w tym przypadku wynikowa liczba cech została każdorazowo ograniczona do 7. Otrzymane wyniki zostały zaprezentowane w tabeli 4.4. Pośród średnich wartości najlepsza kombinacja metod to ponownie średnia wartość absolutna i 10-NN z wynikiem 0.75. Najgorsza wartość klasyfikacji dla takiego zestawu to 0.70, a najlepsza to 0.79.

Ostatnią z metod selekcji, która została wykorzystana na etapie prowadzenia doświadczenia, to eliminacja po wariancji. Podobnie jak metryka Fishera jest to metoda należąca do grupy filtrów. W odróżnieniu od sekwencyjnej selekcji wstecznej metody z grupy filtrów działają bardzo szybko. Otrzymane na tym etapie wyniki zostały zaprezentowane w tabeli 4.5. Podobnie jak poprzednio najlepsza kombinacja metod pod względem poprawności rozpoznawania to średnia wartość absolutna i 10-NN. W tym przypadku średnia wartość poprawnej klasyfikacji wyniosła 0.73 przy najgorszym przypadku wynoszącym 0.70 i najlepszym równym 0.78.

Spośród wszystkich przeprowadzonych badań dla przedstawionego problemu najlepszym okazało się zastosowanie metody krótkoczasowej transformacji Fouriera do pozyskania zbioru cech sygnału. Przy pominięciu etapu selekcji oraz z metodą uczenia maszynowego, jaką jest k-NN z parametrem $k = 10$, najlepszy otrzymany wynik to 0.94 przy średnim poprawnym rozpoznawaniu równym 0.91

W celu zbadania poprawności otrzymanych danych dla wyników otrzymanych z najlepszego zestawu metod został przeprowadzony test studenta. Parametr jaki zostanie sprawdzony, to poprawność klasyfikacji przy ustalonym poziomie istotności.

Dla testu studenta zostały postawione dwie hipotezy:

H_0 : średnia wartość rozpoznawania a_0 dla kombinacji metod MAV i 10-NN jest większa, bądź równa 0.88 ($a \geq a_0$),

H_1 : średnia wartość rozpoznawania a_0 dla kombinacji metod MAV i 10-NN jest mniejsza od 0.88 ($a < a_0$).

Dla $n = 30$ pomiarów z losowo wybranym zbiorem testowym i zbiorem uczącym wartość parametru t statystyki testu studenta wynosi

$$t = \frac{\bar{y} - a_0}{s^2} \cdot \sqrt{n} = 3.49, \quad (4.3)$$

gdzie rozmiary zbioru testowego i zbioru uczącego wynosiły odpowiednio 0.2 i 0.8 liczności pełnego zbioru. Podział taki został zastosowany ze względu na użytą wcześniej walidację krzyżową w przypadku której stosunek liczby próbek uczących do próbek testujących wynosił również 0.25. Wartość średnia z pomiarów wyniosła $\bar{y} = 0.89$ oraz odchylenie standardowe $s^2 = 0.01$.

Dla wyliczonych parametrów hipoteza H_0 została potwierdzona na poziomie istotności równym 0.01.

4.6 Rozpoznawanie wieloetapowe

4.6.1 Założenia

Doświadczenie zostanie przeprowadzone przy pomocy danych elektromiograficznych opisanych w rozdziale 4.3.1. Zestaw metod, jakie zostaną wykorzystane w procesie rozpoznawania, to krótkoczasowa transformacja Fouriera do ekstrakcji cech oraz k-NN jako algorytm klasyfikacji z wartością parametru $k = 10$.

4.6.2 Cel

Celem doświadczenia jest zbadanie błędu rozpoznawania dla klasyfikacji wieloetapowej. Dodatkowo zostaje przyjęte założenie, że proces decyzyjny w pierwszym węźle zbudowanego drzewa zostanie przeprowadzony dla czasu do $300ms$.

Budowanie drzewa decyzyjnego zostanie przeprowadzone przy pomocy dwóch algorytmów poprzez:

- przegląd zupełny,
- analizę statystyki.

4.6.3 Przebieg

4.6.3.1 Wstępna analiza przydatności sygnału pomiarowego

Aby zbadać podejście etykietowania intencji ruchu przy ograniczonych danych pomiarowych (początkowe fazy rejestracji), sygnał elektromiograficzny został podzielony na 20 segmentów z których każdy trwał po $100ms$. Akwizycja danych pomiarowych w czasie rzeczywistym została zasymulowana poprzez dołączanie kolejnych interwałów czasowych w segmenty o długości T_S wynoszącej kolejno:

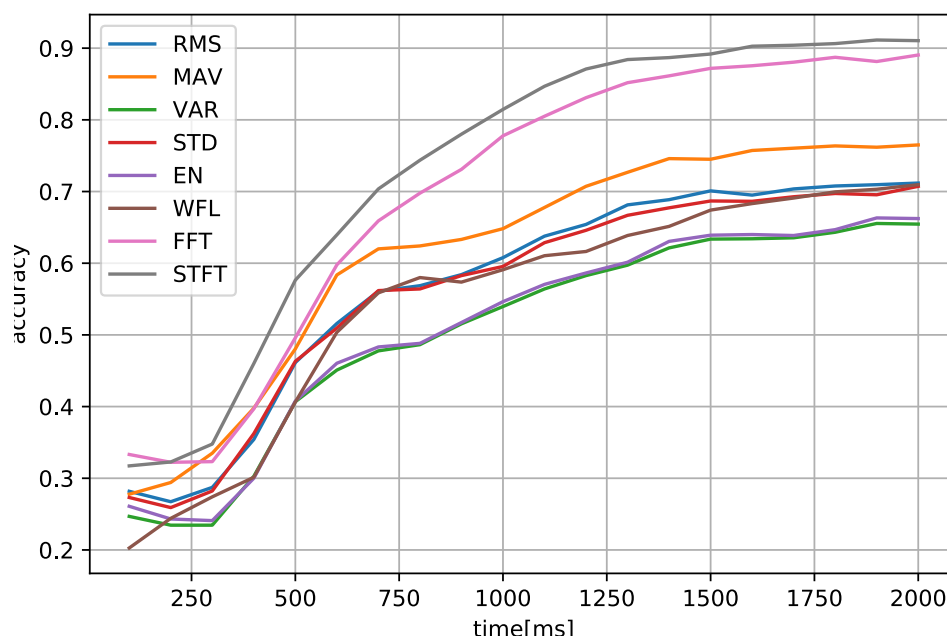
$$T_S \in \{100ms, 200ms, 300ms, \dots, 2000ms\} \quad (4.4)$$

Następnie został przeprowadzony proces ekstrakcji cech i klasyfikacji. Dla każdej długości sygnału z osobna (wzór 4.4). Metody ekstrakcji jakie zostały wykorzystane to

- średnia kwadratowa (RMS),
- średnia wartość absolutna (MAV),
- wariancja (VAR),
- odchylenie standardowe (STD),
- energia (EN),
- długość obwiedni sygnału(WFL),
- szybka transformacja Fouriera (FFT),
- krótkoczasowa transformacja Fouriera (STFT).

Jako model klasyfikatora przyjęto kNN z parametrem k równym 10. Algorytmy zostały dokładniej opisane w rozdziale 3.1.2 i 3.1.4. Badanie i dyskusja nad wyborem współczynnika dla klasyfikatora k najbliższych sąsiadów zostały przeprowadzone w rozdziale 4.4.

Wykres (rys. 4.9) ilustruje błąd etykietowania w zależności od długości dostępnego sygnału czasowego. Zgodnie z przedstawionymi danymi sygnał pomiarowy o długości około 1s został poprawnie rozpoznany w około 80% dla krótkoczasowej transformacji Fouriera oraz dla szybkiej transformacji Fouriera. Dla metod, z których otrzymywane są cechy czasowe, poprawna klasyfikacja była przeprowadzona z dokładnością od około 55% do około 65%. Ekstrakcja cech została przeprowadzona bez dodatkowego podziału sygnału na przedziały czasowe. Podejście takie zapewnia stałą długość wektora cech niezależnie od długości sygnału wejściowego. Charakterystyczne własności sygnału dla danego przedziału czasowego są w tym przypadku tracone, a decydującymi cechami są te, które charakteryzują daną klasę na całym przedziale czasowym sygnału.



Rysunek 4.9: Poprawność rozpoznawania w zależności od długości sygnału

W kolejnym kroku ponownie została zbadana poprawność rozpoznawania intencji ruchu dla danych wejściowych o długości należącej do zbioru T_S (wzór 4.4).

W tym przypadku sygnał pomiarowy został podzielony na kolejne segmenty o długości $100ms$ niezależnie od swojej długości. Dane z każdego segmentu zostały poddane procesowi ekstrakcji cech tworząc wektor cech z połączonych informacji z każdego z segmentów. Długość wektora cech jest w takim przypadku uzależniona od długości sygnału czasowego i wynosi

$$|F| = N_{CH} \cdot \frac{T_S}{N_S} \cdot N_F, \quad (4.5)$$

gdzie:

N_{CH} – jest liczbą kanałów pomiarowych,

T_S – jest liczbą próbek w sygnale,


N_F – jest liczbą cech otrzymanych z metody ekstrakcji,

N_S – jest długością pojedynczego segmentu na które dzielony jest dostępny sygnał pomiarowy.

W badanym przypadku występuje 8 kanałów pomiarowych sygnału elektromiograficznego. Długość pojedynczego segmentu (N_S) jest równa $100ms$. Dla tak dobranych parametrów długość wektora cech zawiera się w przedziale:

$$|F| \in \{8, 16, 24, \dots, 160\} \quad (4.6)$$

dla metod wyliczających po jednej cesze z badanego sygnału.



Rysunek 4.10: Poprawność rozpoznawania w zależności od długości sygnału dla sygnału wstępnie podzielonego na segmenty o długości $100ms$

Wyniki badania zostały przedstawione na rysunku 4.10. Podobnie jak w poprzednim przypadku (rys. 4.9) średni błąd rozpoznawania malał wraz ze wzrostem długości dostępnego sygnału pomiarowego. Dla sygnału o długości $1s$ wyniósł około 20%

dla zbiorów cech otrzymanych z krótkoczasowej transformacji Fouriera oraz z szybkiej transformacji Fouriera. Dla sygnału o długości $0.5s$ system poprawnie sklasyfikował co najmniej połowę pomiarów testowych dla wszystkich badanych metod ekstrakcji z wyłączeniem wariacji i energii sygnału. Dla pełnej długości sygnału poprawne przyporządkowano około 90% danych dla szybkiej transformacji Fouriera.

Rysunek 4.11 przedstawia różnicę w błędzie rozpoznawania dla poszczególnych algorytmów ekstrakcji cech. Porównane zostały wyniki otrzymane przy pomocy pojedynczego wektora cech z pełnego sygnału i z wektora cech utworzonego z połączenia cech z kolejnych segmentów sygnału pomiarowego, gdzie długość kolejnych segmentów wynosił T_S .

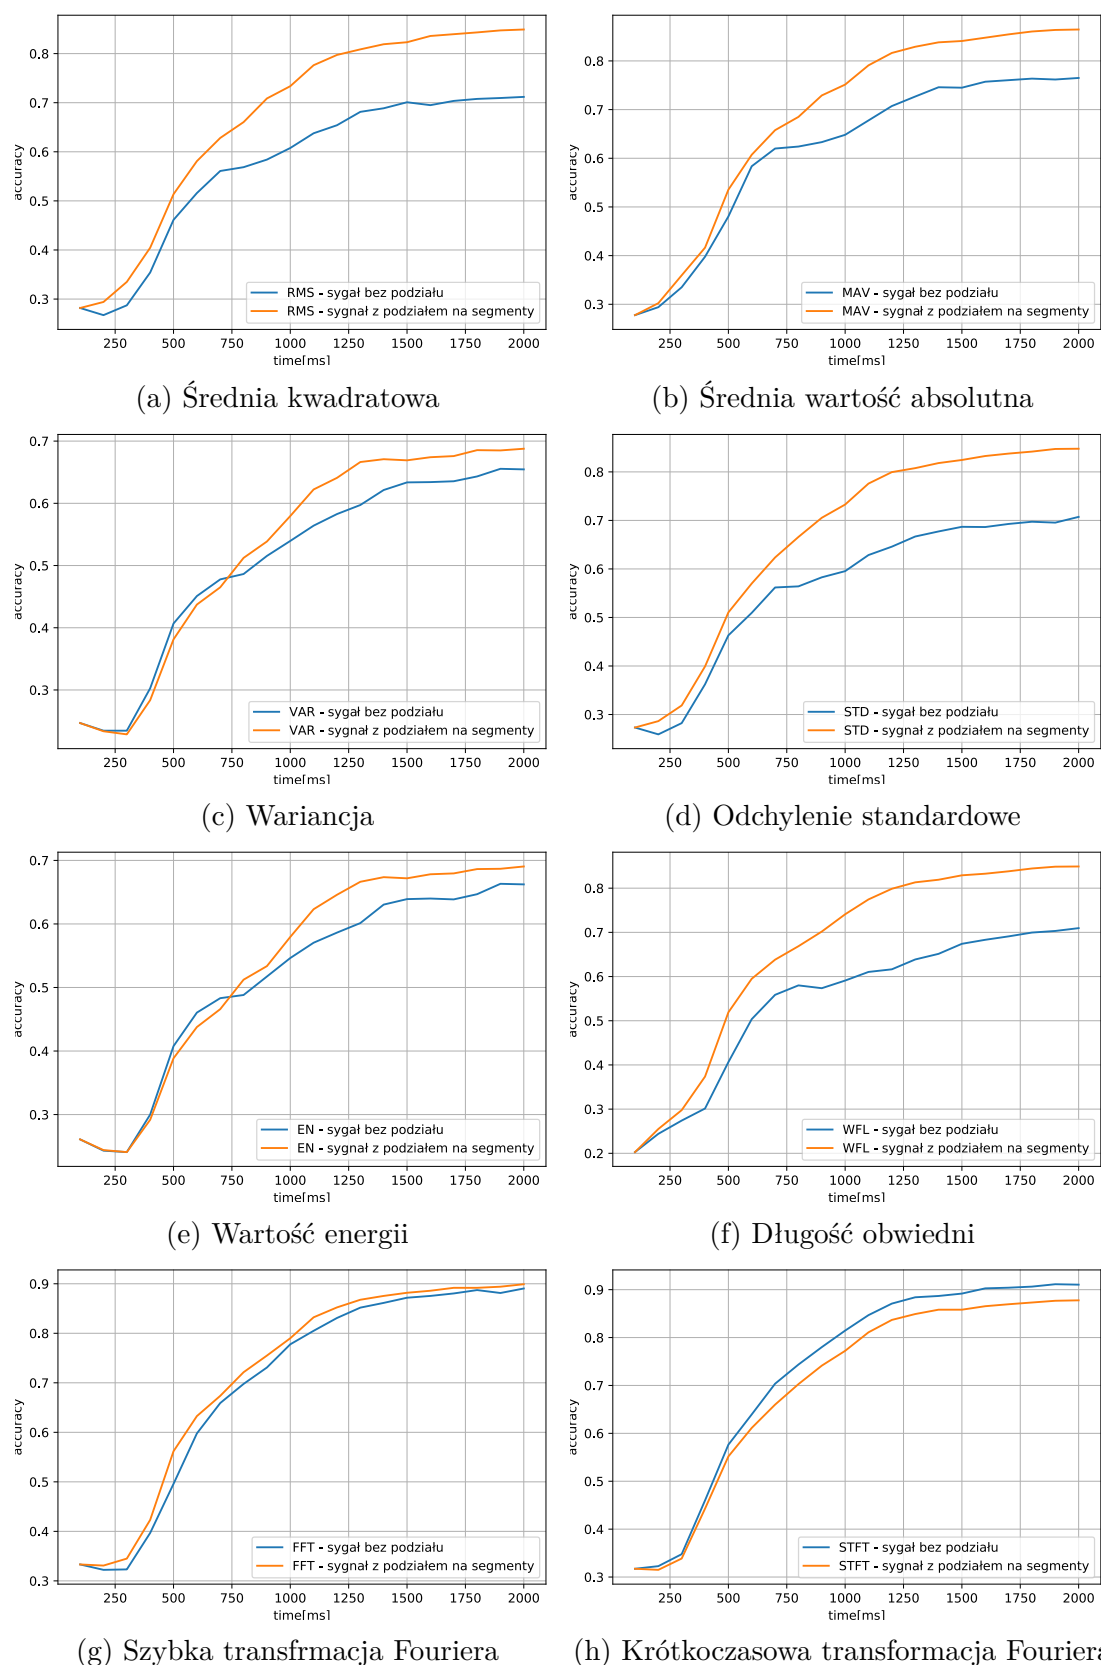
Zgodnie z otrzymanymi danymi w siedmiu z ośmiu przypadków można zauważyć znaczącą poprawę jakości rozpoznawania po podzieleniu sygnału wejściowego na segmenty o długości $100ms$ (rys. 4.11). Są to wszystkie metody pozyskiwania cech sygnału z wyłączeniem krótkoczasowej transformacji Fouriera. W przypadku krótkoczasowej transformacji Fouriera można zauważyć pogorszenie poziomu poprawnego klasyfikowania po zastosowaniu podziału danych wejściowych. Porównując ze sobą wykresy 4.9 i 4.10 można zauważyć, że w przypadku operowania na pełnym sygnale najlepiej spisują się algorytmy częstotliwościowe (FFT i STFT). Metody operujące w dziedzinie czasu dają zdecydowanie gorsze wyniki. Natomiast, kiedy sygnał jest wstępnie dzielony na interwały o długości $100ms$ różnica ta zdaje się być zdecydowanie mniejsza.

Analizując dane z wykresów 4.9, 4.10 i 4.11 wytypowano najefektywniejsze algorytmy ekstrakcji cech z grupy algorytmów czasowych i częstotliwościowych. Taką parą jest średnia wartość absolutna operująca na sygnale czasowym podzielonym na segmenty i krótkoczasowa transformacja Fouriera wyliczana z pełnej długości dostępnego sygnału.

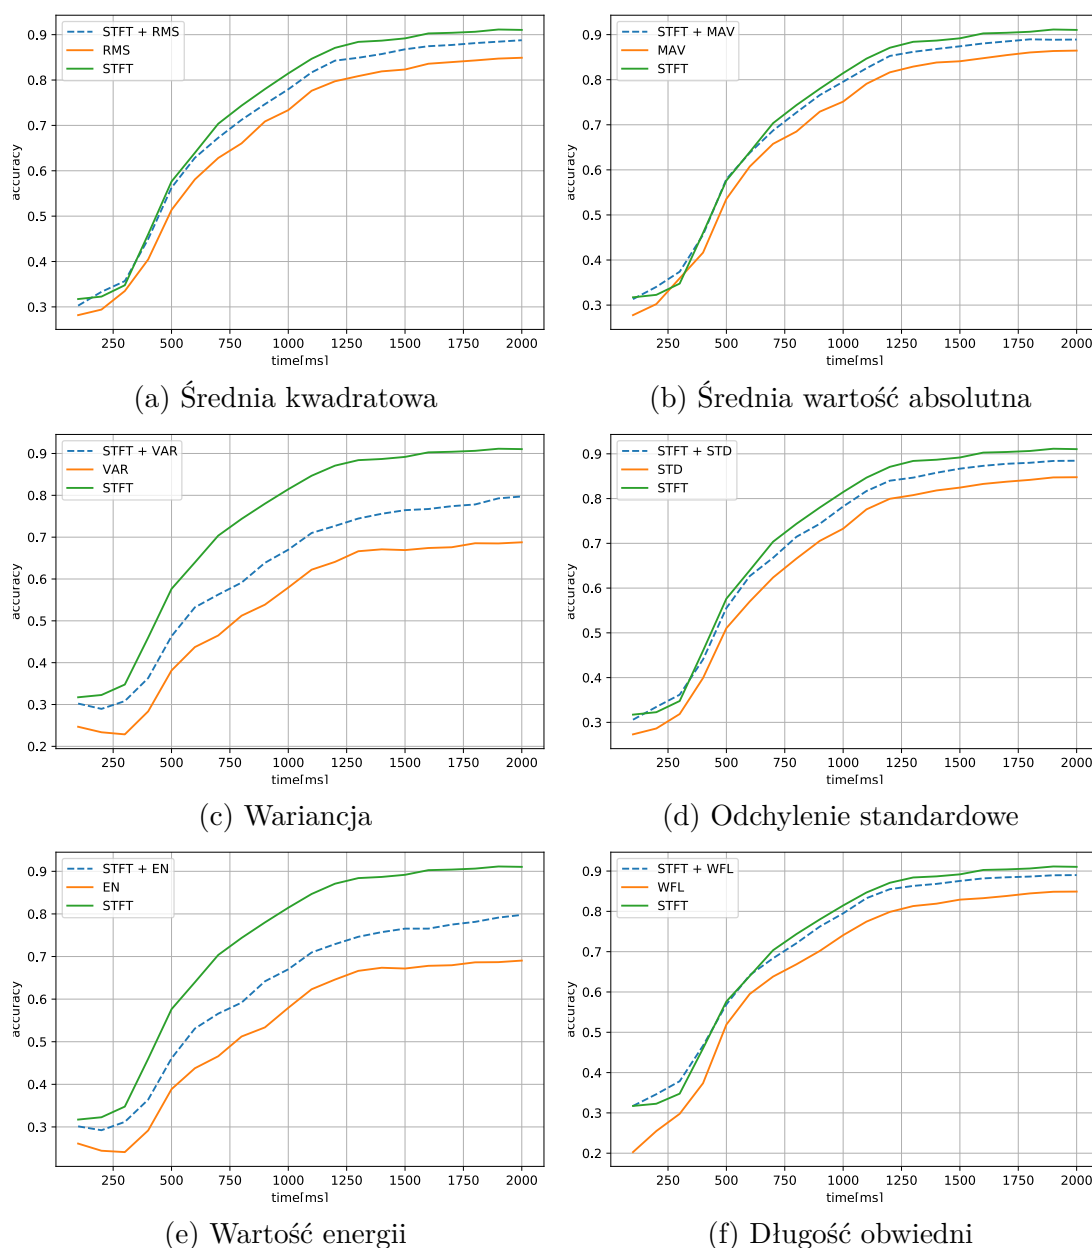
Dodatkowo został zbadany wpływ połączenia ze sobą algorytmu krótkoczasowej transformacji Fouriera z każdą z metod czasowych. Wyniki zostały przedstawione na rysunku 4.12.

Wektory cech otrzymane z STFT i MAV zostały poddane normalizacji przed konkatenacją. Wykorzystana została norma Frobeniusa będąca uogólnieniem normy Euklidesowej [94–96]. Norma $\|A\|_F$ jest pierwiastkiem sumy kwadratów wszystkich elementów macierzy \hat{F}

$$\|A\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |\hat{F}_{ij}|^2}, \quad (4.7)$$



Rysunek 4.11: Porównanie poprawności rozpoznawania dla sygnału oryginalnego i podzielonego na segmenty



Rysunek 4.12: Porównanie poprawności rozpoznawania dla sygnału oryginalnego z metody czasowej pozyskiwania cechy i podzielonego na segmenty sygnału poddanego STFT

gdzie \hat{F}_{ij} jest elementem macierzy z i -tego wiersza i j -tej kolumny. Macierz \hat{F}_{ij} powstała po połączeniu ze sobą wektorów cech wyliczonych przy pomocy pojedynczej metody ekstrakcji. W kolejnych kolumnach macierzy znajdują się kolejne cechy z wektora cech (wzór 4.8).

$$\hat{F}_{n \times m} = \begin{bmatrix} f_{1,1} & f_{1,2} & f_{1,3} & \cdots & f_{1,n} \\ f_{2,1} & f_{2,2} & f_{2,3} & \cdots & f_{2,n} \\ f_{3,1} & f_{3,2} & f_{3,3} & \cdots & f_{3,n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f_{m,1} & f_{m,2} & f_{m,3} & \cdots & f_{m,n} \end{bmatrix}, \quad (4.8)$$

gdzie $f_{m,n}$ jest n -tą cechą z m -tego pomiaru.

W szczególnym przypadku, dla metody dającej pojedynczą cechę, macierz będzie posiadała tylko jedną kolumnę. W wierszach macierzy natomiast znajdują się kolejne wektory cech wyliczone dla kolejnych pomiarów sygnału.

Dla tak wyliczonego $\|A\|_F$ każdy element z macierzy \hat{F} zostaje podzielony przez wyliczoną normę $\|A\|_F$.

Połączenie wektora cech STFT i MAV daje nieznacznie gorsze efekty dla długości sygnału wejściowego od $600ms$ do $2000ms$ w porównaniu do wyników otrzymanych z samego STFT. W przypadku sygnału od 0 do $300ms$ połączony wektor okazuje się być lepszy ze względu na poprawność klasyfikowania dla badanych danych pomiarowych. W przedziale od $300ms$ do $600ms$ nie ma istotnych różnic pomiędzy STFT, a połączonym STFT i MAV.

4.6.3.2 Klasyfikacja sekwencyjna sygnału o rosnącej długości

Czas klasyfikacji sygnału pomiarowego dla danych elektromiograficznych jest problemem niezwykle istotnym. Wraz ze wzrostem szybkości reakcji robotycznej protezy, czyli skróceniem czasu potrzebnego na rozpoczęcie wykonywania ruchu przez urządzenie, rośnie jego użyteczność.

Badania dowodzą, że optymalne opóźnienie protezy wynosi $100ms$ dla szybkich chwytów i $125ms$ dla chwytów powolnych [19]. Wraz z liniowym wzrostem opóźnienia reakcji protezy, wzrasta pogorszenie wydajności urządzenia. Czas na reakcję protezy od momentu pojawienia się intencji ruchu wynosi jedynie $100ms - 125ms$. W przeciwnym wypadku opóźnienie zaczyna być odczuwalne przez użytkownika i maleje odczuwalna reaktywność protezy.

Zaprezentowane wyniki dla sygnału pomiarowego niepodzielonego na dodatkowe segmenty (rys. 4.9) i dla sygnału podzielonego na segmenty czasowe (rys. 4.10) pokazują, że przy klasycznym podejściu (rys. 3.1) nie jest możliwe zaprojektowanie systemu o błędzie dokładności klasyfikacji zbiegającym do zera ($\epsilon \rightarrow 0$) przy jednoczesnym czasie akwizycji

sygnału pomiarowego również zbiegającym do zera ($T_S \rightarrow 0$) lub jak pokazały badania dla sygnału pomiarowego równego $100ms$ z pominięciem czasu potrzebnym na analizę i przetwarzanie sygnału oraz proces decyzyjny.

W prezentowanym przykładzie każdy z pomiarów przyporządkowany jest do jednej z 11 klas ruchów. Jak pokazują przeprowadzone badania dla zastosowanych metod ekstrakcji cech, selekcji i klasyfikacji przy tak licznych zbiorze nie jest możliwa klasyfikacja sygnału krótszego niż $1s$ z błędem rozpoznawania mniejszym niż 10% (rys. 4.9 i 4.10). Najlepszy wynik jaki udało się osiągnąć, to błąd rzędu 20% dla sygnału o długości $1s$ przy zastosowaniu algorytmu krótkoczasowej transformacji Fouriera (STFT) liczonej z pełnej długości sygnału. Niewiele gorsza okazała się metoda liczenia zbioru cech za pomocą szybkiej transformacji Fouriera (FFT) liczonej z segmentów o długości $100ms$.

Aby zbadać błąd rozpoznawania w stosunku do długości sygnału, został on podzielony na krótsze interwały czasowe. Problem etykietowania intencji ruchu został rozpatrzony w kontekście krótkiego interwału czasu ($100ms$), lub jego wielokrotności (równanie 4.4).

Na tym etapie przyporządkowywanie następuje do grupy klas, a nie bezpośrednio do samej klasy. Opracowywanie drzewa decyzyjnego, a więc łączenie klas w grupy może zostać przeprowadzone na dwa sposoby:

- przegląd zupełny,
- analizę statystyki.

Każda z metod została opisana w rozdziale 3.2.5.

Dzieląc zbiór klas na dwie grupy zostało przyjęte założenie, że musi zostać zachowana licznosc zbioru, która wynosi co najmniej jeden element w każdej grupie. Ponadto każda z klas w dzielonej grupie może wystąpić tylko w jednej podgrupie. Grupy nie będące w jednej gałęzi drzewa decyzyjnego są ze sobą rozłączne. Nie ma możliwości wystąpienia klasy w więcej niż jednej grupie. Co więcej grupa o licznosci jeden oznacza ruch końcowy.

Na podstawie wyników z poprzedniego rozdziału do dalszych badań zostały wytypowane algorytmy:

- Ekstrakcja – MAV dla segmentów o długości $100ms$ oraz STFT dla sygnału niepodzielonego na mniejsze segmenty.
- Klasyfikacja – algorytm k najbliższych sąsiadów jako model predykcyjny z liczbą najbliższych sąsiadów wynoszącą 10.

Do badania został wykorzystany zbiór danych szerzej opisany w rozdziale 4.3.1. Sygnał pomiarowy został podzielony na segmenty o długości $100ms$. Jest to najmniejsza rozdzielczość o jaką może zostać zmieniona długość sygnału. Badania zostały przeprowadzone dla sygnału elektromiograficznego z pominięciem sygnału mechanomiograficznego z powodu uproszczenia etapu wyliczania wektora cech. Sygnały o dwóch różnych modalnościach wymagają rozdzielnych procesów ekstrakcji, które przeprowadzane są równoległe z odpowiednio dobranymi algorytmami dla każdej modalności z osobna.

Badanie zostało podzielone na kilka iteracji. Każda z iteracji różni się od poprzedniej tym, że klasy ruchów zostają podzielone na coraz to mniejsze podzbiory zgodnie z jedną z przyjętych strategią budowania drzewa decyzyjnego. W szczególnym przypadku podział nie następuje i zbiory klas ruchów są takie same jak w iteracji poprzedzającej. Co więcej długość dostępnego sygnału w i -tej iteracji (T_i) jest wielokrotnością $100ms$ i wynosi

$$T_i = i \cdot 100[ms]. \quad (4.9)$$

Stąd ze względu na długość sygnału wynoszącą $2000ms$ maksymalna liczba iteracji dla przyjętych danych pomiarowych wynosi 20 ($T_{20} = 2000ms$).

4.6.3.3 Przegląd zupełny z warunkiem na średni poziom rozpoznawania

Badanie budowania drzewa decyzyjnego poprzez przegląd zupełny została opisana w rozdziale 3.2.5.

Sekwencyjna selekcja – pierwsza iteracja ($T_1 = 100ms$)

Dla tak przedstawionego problemu przeprowadzona została pierwsza iteracja pomiędzy zbiorem 11 różnych klas ruchów. Początkowa długość sygnału została wybrana w taki sposób, żeby średnia wartość przyporządkowania ruchów do utworzonych grup była nie mniejsza niż 90%. W celu wyznaczenia średniej wartości klasyfikacji została wykorzystana walidacja krzyżowa z 5-cio krotnym podziałem.

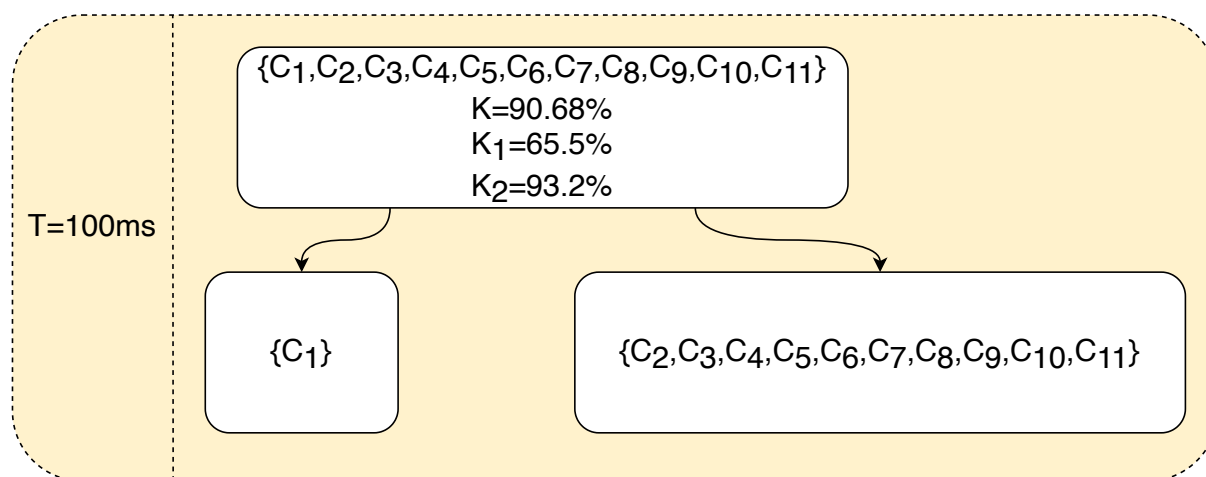
Początkowa grupa przed podziałem wynikającym z pierwszej iteracji zawiera klasy:

$$G = \{C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}\}. \quad (4.10)$$

Dla podziału G na G_1 i G_2 został przeprowadzony przegląd zupełny po wszystkich kombinacjach klas w podgrupach. Największa średnia wartość poprawnej klasyfikacji wynosi 90.68% i dotyczy podziału na

$$\begin{cases} G_1 = \{C_1\} \\ G_2 = \{C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}\} \end{cases} \quad (4.11)$$

Ze względu na różną licznosc zbiorów G_1 oraz G_2 na które dzielone są ruchy, wykorzystana została średnia ważona z wagami równymi licznosci każdego ze zbiorów liczona zgodnie ze wzorem



Rysunek 4.13: Podział klas z grupy G na G_1 i G_2

$$K_i = \frac{|G_{i1}|K_{i1} + |G_{i2}|K_{i2}}{|G_i|}, \quad (4.12)$$

gdzie:

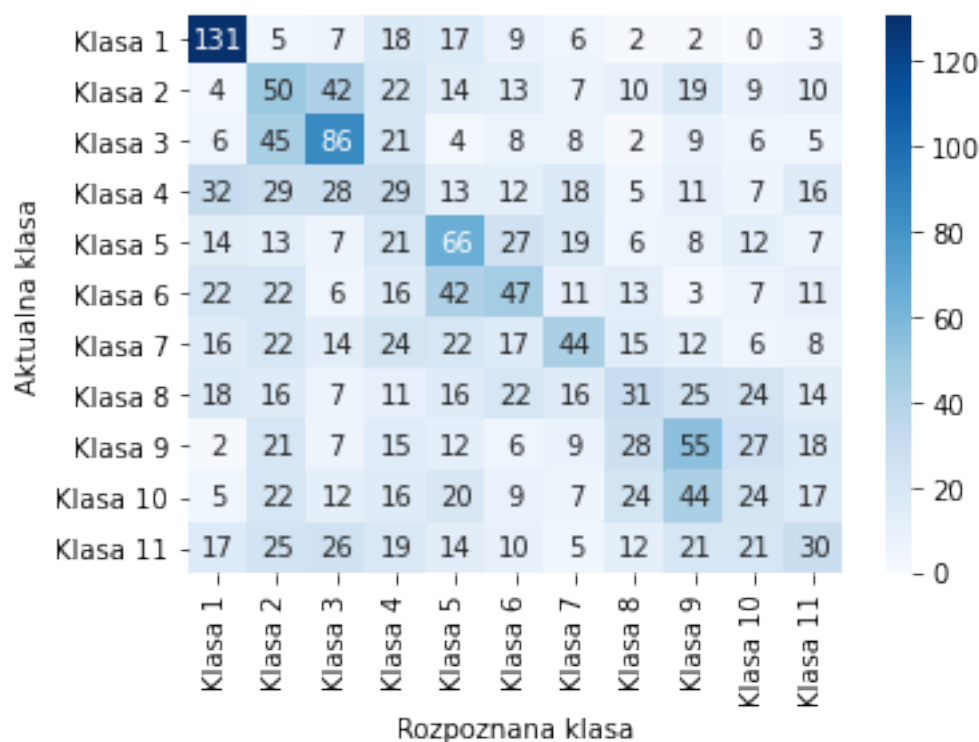
$|G_i|$ – jest liczbą elementów w zbiorze klas G_i ,

K_{i1} – jest wartością określającą poprawność klasyfikacji sygnałów do grupy G_{i1} ,

K_i – jest średnią wartością przyporządkowywania zbioru cech do grupy G_{i1} i G_{i2} .

Wartość poprawnej klasyfikacji jest większa od 90%, więc postawiony warunek został spełniony. Algorytm przechodzi do kolejnej iteracji z podziałem na G_1 i G_2 . Macierz błędów dla klas należących do G została przedstawiona na rysunku 4.14.

Zbiór klas z G_1 jest jednoelementowy. Dla klasy należącej do tej grupy dalsza analiza nie będzie już przeprowadzana.

Rysunek 4.14: Macierz błędów dla klas z grupy G

Wyniki przeglądu zupełnego dla wszystkich możliwych kombinacji podziału klas z grupy G na G_1 oraz G_2 zostały ujęte w rozdziale z dodatkami w tabeli 6.1.


Sekwencyjna selekcja – druga iteracja ($T_2 = 200ms$)

Druga iteracja dotyczy klas z grupy G_2 . Dla symulacji przeprowadzonej po uzyskaniu sygnału o długości 200ms najlepszy podział został wykonany dla

$$\begin{cases} G_{21} = \{C_{11}\} \\ G_{22} = \{C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}\} \end{cases} \quad (4.13)$$

Macierz błędów dla klas należących do G_2 została przedstawiona na rysunku 4.15.

Grupa G_{21} została poprawnie rozpoznana w 19%. Grupa G_{22} natomiast w 95.39%. Końcowa wartość poprawnej klasyfikacji jaka została przyjęta na tym etapie wynosi 87.75%. Warunek o wartości rozpoznawania na poziomie co najmniej 90% nie został spełniony.

Rysunek 4.15: Macierz błędów dla klas z grupy G_2 **Sekwencyjna selekcja – trzecia iteracja ($T_3 = 300ms$)**

Najlepsza średnia wartość klasyfikacji dla trzeciej iteracji wynosi 89.3% dla takiego samego podziału na podgrupy jak w drugiej iteracji.

Macierz błędów w trzeciej iteracji dla klas znajdujących się w G_2 została przedstawiona na rysunku 4.16.

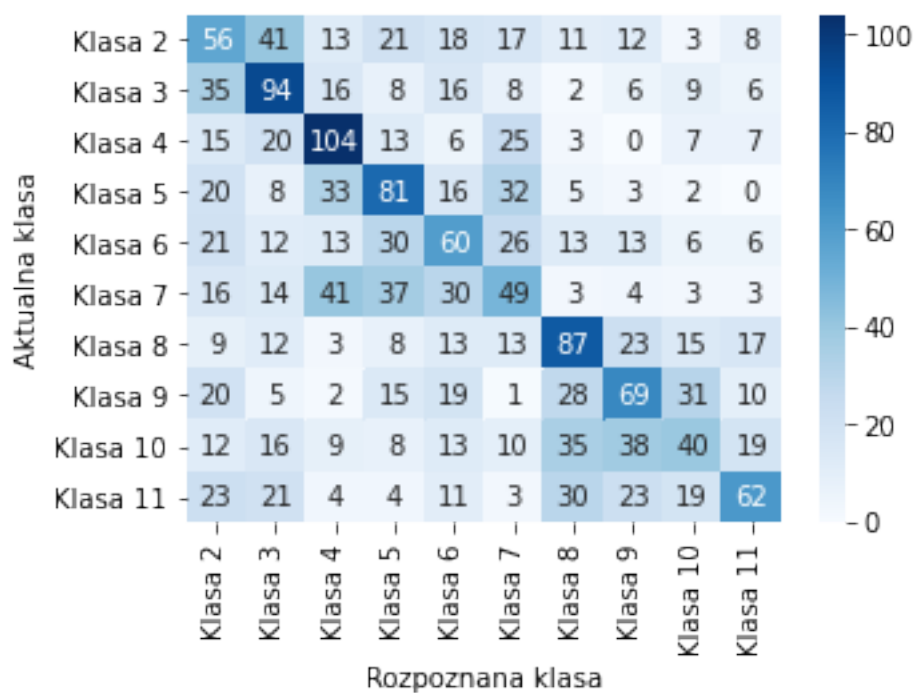

Sekwencyjna selekcja – czwarta iteracja ($T_4 = 400ms$)

Najlepsza średnia wartość rozpoznawania wynosi 92% dla podziału na grupy

$$\begin{cases} G_{21} = \{C_4\} \\ G_{22} = \{C_2, C_3, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}\} \end{cases} \quad (4.14)$$

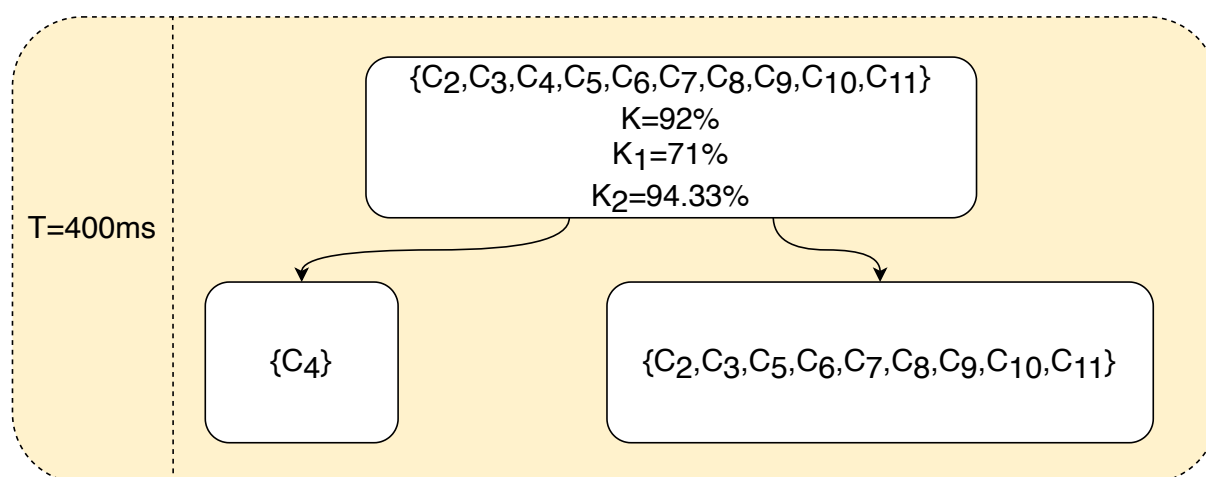
Poziom poprawności rozpoznawania dla G_{21} wynosi 71%, dla G_{22} jest to 94.33%

Macierz błędów dla grupy G_2 został przedstawiony na rysunku 4.17.

Rysunek 4.16: Macierz błędów dla klas z grupy G_2 Rysunek 4.17: Macierz błędów dla klas z grupy G_2

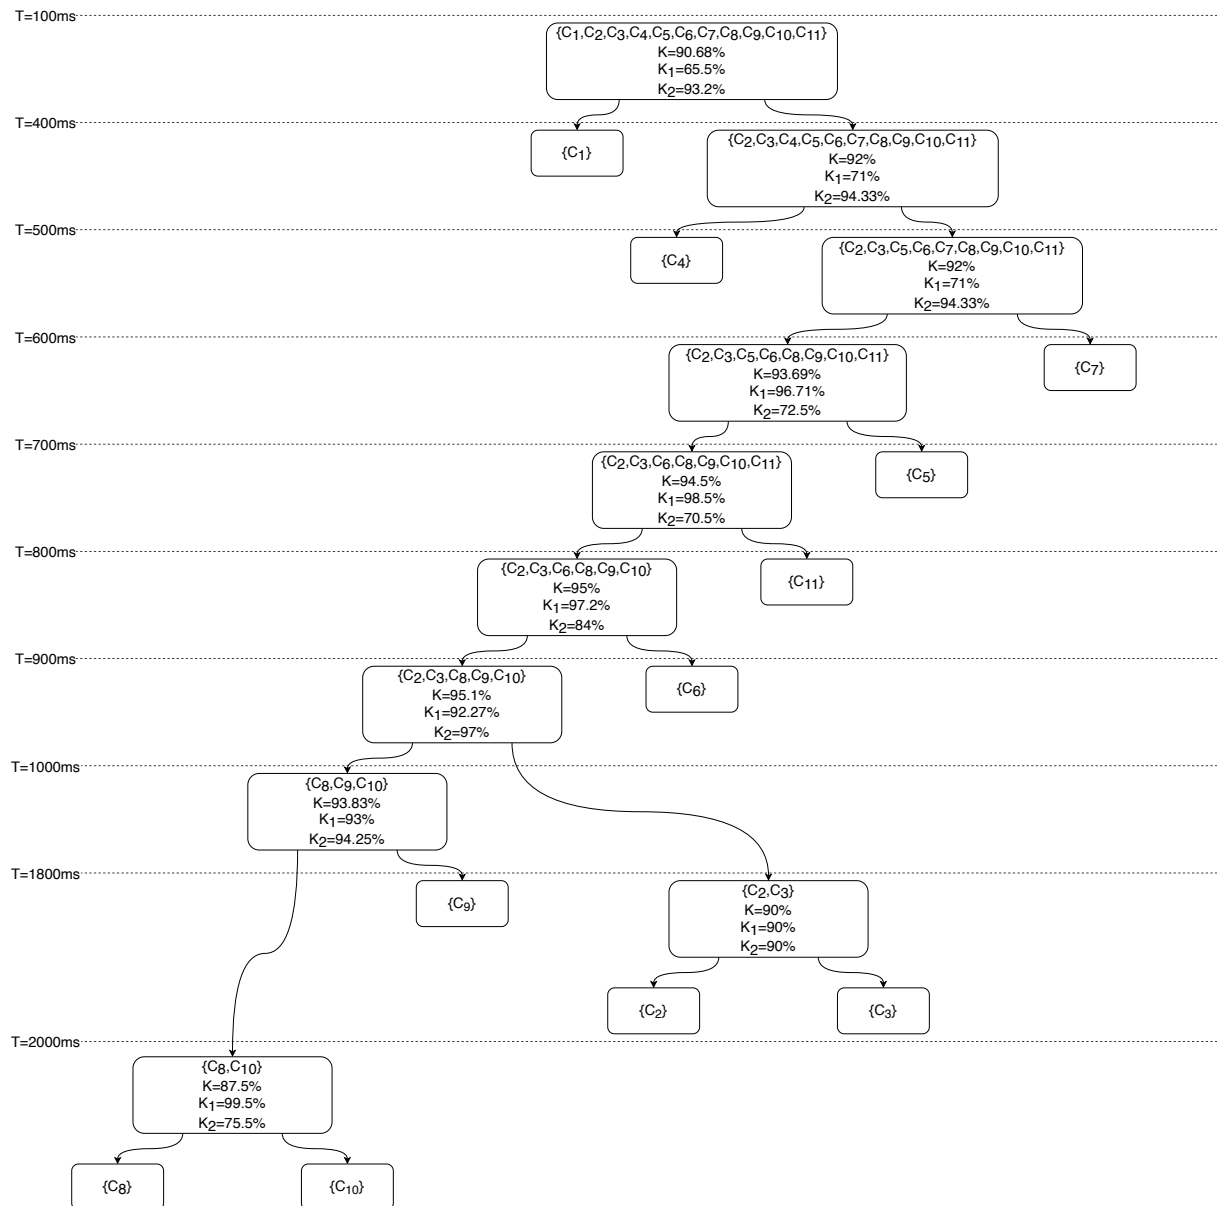
Sekwencyjna selekcja – kolejne iteracja

Dalsze iteracje zostaną przeprowadzone analogicznie do pierwszych trzech etapów iteracji algorytmu klasyfikacji sekwencyjnej. Na podstawie weryfikacji modelu klasyfikatora w

Rysunek 4.18: Podział klas z grupy G_2 na G_{21} i G_{22}

każdej grupie zostaną wytypowane dwie podgrupy klas o licznosci co najmniej 1 każda. Wraz ze wzrostem długości sygnału pomiarowego klasy zostają podzielone na coraz to mniejsze grupy do momentu, aż wszystkie klasy znajdują się w jednoelementowych zbiorach, czyli zostaną ostatecznie sklasyfikowane jako ruchy końcowe. Zgodnie z wcześniejszym założeniem o dopuszczalnym warunku podziału klas, czyli dopiero w momencie, kiedy wartość rozpoznawania wynosi co najmniej 90% sprawdzane jest, czy warunek ten jest spełniony. W przypadku, kiedy sygnał pomiarowy osiągnie maksymalną długość $2000ms$ i założenie nadal nie jest spełnione, sekwencyjna selekcja zostaje wykonana przy niższym progu akceptacji. Moment klasyfikacji zostaje dobrany w taki sposób, żeby osiągnąć jak najmniejszy błąd rozpoznawania.

Wyniki przeprowadzonej symulacji począwszy od pierwszego, a skończywszy na ostatnim etapie iteracji algorytmu sekwencyjnej selekcji zostały zaprezentowane na rysunku 4.19 w postaci drzewa sekwencyjnej klasyfikacji.



Rysunek 4.19: Diagram rozpoznawania wieloetapowego otrzymanego przy pomocy przeglądu zupełnego dla progu akceptacji na poziomie 90%

Tabela. 4.6: Wyniki klasyfikacji wieloetapowej dla przeglądu zupełnego i warunku na średnią wartość rozpoznawania nie mniejszą od 90%

$T[m.s]$	G_i	G_{i1}	G_{i2}	$K[\%]$	$K_1[\%]$	$K_2[\%]$
100	$C_1, C_2, C_3, C_4, C_5,$ $C_6, C_7, C_8, C_9, C_{10}, C_{11}$	C_1	$C_2, C_3, C_4, C_5, C_6,$ $C_7, C_8, C_9, C_{10}, C_{11}$	90.68	65.5	93.2
200	$C_2, C_3, C_4, C_5, C_6,$ $C_7, C_8, C_9, C_{10}, C_{11}$	C_{11}	$C_2, C_3, C_4, C_5, C_6,$ C_7, C_8, C_9, C_{10}	87.75	19	95.39
300	$C_2, C_3, C_4, C_5, C_6,$ $C_7, C_8, C_9, C_{10}, C_{11}$	C_{11}	$C_2, C_3, C_4, C_5, C_6,$ C_7, C_8, C_9, C_{10}	89.3	31	95.78
400	$C_2, C_3, C_4, C_5, C_6,$ $C_7, C_8, C_9, C_{10}, C_{11}$	C_4	$C_2, C_3, C_5, C_6,$ $C_7, C_8, C_9, C_{10}, C_{11}$	92	71	94.33
500	$C_2, C_3, C_5, C_6,$ $C_7, C_8, C_9, C_{10}, C_{11}$	C_7	$C_2, C_3, C_5, C_6,$ C_8, C_9, C_{10}, C_{11}	91.78	70	94.5
600	$C_2, C_3, C_5, C_6,$ C_8, C_9, C_{10}, C_{11}	C_5	$C_2, C_3, C_6,$ C_8, C_9, C_{10}, C_{11}	93.69	72.5	96.71
700	$C_2, C_3, C_6,$ C_8, C_9, C_{10}, C_{11}	C_{11}	$C_2, C_3, C_6,$ C_8, C_9, C_{10}	94.5	70.5	98.5
800	$C_2, C_3, C_6,$ C_8, C_9, C_{10}	C_6	$C_2, C_3,$ C_8, C_9, C_{10}	95	84	97.2
900	$C_2, C_3, C_8, C_9, C_{10}$	C_2, C_3	C_8, C_9, C_{10}	95.1	92.25	97
1000	C_2, C_3	C_2	C_3	74	77	71
1000	C_8, C_9, C_{10}	C_9	C_8, C_{10}	93.83	93	94.25
1100	C_2, C_3	C_2	C_3	82.25	84	80.5
1100	C_8, C_{10}	C_8	C_{10}	74.75	88	61.5
1200	C_2, C_3	C_2	C_3	86.25	87	85.5
1200	C_8, C_{10}	C_8	C_{10}	77.25	91	63.5
1300	C_2, C_3	C_2	C_3	87.75	88	87.5
1300	C_8, C_{10}	C_8	C_{10}	79.5	94.5	64.5
1400	C_2, C_3	C_2	C_3	88	87.5	88.5
1400	C_8, C_{10}	C_8	C_{10}	81.75	97	66.5
1500	C_2, C_3	C_2	C_3	87.75	87.5	88
1500	C_8, C_{10}	C_8	C_{10}	82.75	98.5	67
1600	C_2, C_3	C_2	C_3	87.75	87	88.5
1600	C_8, C_{10}	C_8	C_{10}	85	99	71
1700	C_2, C_3	C_2	C_3	88.75	88.5	89
1700	C_8, C_{10}	C_8	C_{10}	85.5	99	72
1800	C_2, C_3	C_2	C_3	90	90	90
1800	C_8, C_{10}	C_8	C_{10}	86	99	73
1900	C_8, C_{10}	C_8	C_{10}	86.75	99	74.5
2000	C_8, C_{10}	C_8	C_{10}	87.5	99.5	75.5

4.6.3.4 Analiza statystyczna

Budowa drzewa decyzyjnego poprzez analizę statystyki zostaje przeprowadzone zgodnie z wytycznymi z rozdziału 3.2.5.2. Podział ruchów na dwa podzbiory zostaje przeprowadzone przy założeniu, że poprawność rozpoznawania każdej z grup (G_{i1} i G_{i2}) jest conajmniej na poziomie 90%. W przypadku, kiedy sygnał osiągnie długość $2000ms$, a założona średnia wartość rozpoznawania nie zostanie osiągnięta, wybierany jest etap o największej osiągniętej wartości rozpoznawania.

Pierwsza iteracja ($T = 100ms$)

W tabeli 4.7 zostały przedstawione dodatkowe dane o grupie G_1 . Dla każdej klasy z grupy został wyliczony wektor cech reprezentujący daną klasę, który jest uśrednieniem wektorów cech wszystkich pomiarów występujących w klasie. Następnie policzono odległości pomiędzy reprezentantami klas dla wszystkich kombinacji par. Wyniki zaprezentowano w tabeli 4.7.

W kolejnym kroku na podstawie odległości między klasami zostały policzone statystyki opisujące zależności między reprezentantami kolejnych klas ruchów:

- wartość minimalna dystansu między klasami,
- wartość maksymalna dystansu między klasami,
- średnia wartość dystansu między klasami,
- odchylenie standardowe dystansu między klasami.

Statystyki zostały policzone osobno dla każdej z klasy. Dane liczbowe dla każdej ze statystyk zostały posortowane rosnąco i przedstawione w tabeli 4.8 razem z numerem klasy dla której została wyliczona dana statystyka.

Zgodnie z danymi z tabeli 4.7 oraz 4.8 najbardziej odległą klasą od pozostałych jest C_1 . Minimalna, maksymalna i średnia odległość, jakie zostały policzone między reprezentantami klas osiągnęły dla C_1 największą wartość.

$$\begin{cases} G_1 = \{C_1\} \\ G_2 = \{C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}\} \end{cases} . \quad (4.15)$$

Tabela. 4.7: Odległości między klasami dla grupy G

C_i	C_j	$d(C_i, C_j)$		5	7	0.1167		2	11	0.160823
9	10	0.0542011		5	9	0.124787		4	9	0.177525
8	11	0.0676329		6	7	0.124827		2	6	0.178193
8	10	0.0690356		9	11	0.126601		3	10	0.185509
6	8	0.079262		6	10	0.129276		3	6	0.186349
2	5	0.0868045		2	3	0.130951		7	10	0.188371
6	11	0.0921528		2	8	0.132364		1	6	0.213136
5	8	0.0965669		5	11	0.133149		1	11	0.213868
10	11	0.100031		7	8	0.135007		7	9	0.216425
2	4	0.101038	...	4	6	0.136804	...	3	9	0.217777
4	7	0.104149		2	10	0.138537		1	7	0.234777
4	5	0.108213		3	11	0.14428		1	4	0.252919
8	9	0.108996		2	7	0.145087		1	8	0.254133
4	8	0.109491		7	11	0.146924		1	3	0.254963
3	4	0.109497		6	9	0.148519		1	5	0.272913
5	10	0.111241		4	10	0.152074		1	10	0.289778
3	7	0.111909		3	5	0.152984		1	9	0.304066
5	6	0.115449		3	8	0.154952		1	2	0.317887
4	11	0.11654		2	9	0.15795				

Tabela. 4.8: Statystyki odległości dla grupy G

C_i	d_i^{min}	C_i	d_i^{max}	C_i	d_i	C_i	d_i^{std}
9	0.0542011	6	0.213136	8	0.120744	1	0.0337782
10	0.0542011	11	0.213868	11	0.1302	11	0.0385963
8	0.0676329	7	0.234777	5	0.131881	6	0.0399542
11	0.0676329	4	0.252919	4	0.136825	7	0.04309
6	0.079262	8	0.254133	6	0.140397	3	0.0441457
2	0.0868045	3	0.254963	10	0.141805	4	0.0452099
5	0.0868045	5	0.272913	7	0.152418	5	0.0501526
4	0.101038	10	0.289778	2	0.154963	8	0.0523121
7	0.104149	9	0.304066	9	0.163685	2	0.0601126
3	0.109497	1	0.317887	3	0.164917	10	0.0647277
1	0.213136	2	0.317887	1	0.260844	9	0.0661321

Klasa C_1 zostaje wytypowana do grupy klas G_1 . Pozostałe klasy zostają przydzielone do G_2 . Podział został wykonany w taki sam sposób jak w przypadku przeglądu zupełnego. Węzeł drzewa decyzyjnego został zaprezentowany na rysunku 4.13.

Druga iteracja ($T = 200ms$)

Na drugim etapie iteracji podobnie jak przy przeglądzie zupełnym nie został spełniony warunek minimalnego poprawnego rozpoznawania na poziomie 90%.

Tabela. 4.9: Ranking odległości dla G

C_i	p_i
11	8
8	9
6	11
4	16
10	16
5	17
7	19
9	19
2	25
3	26
1	32

Trzecia iteracja ($T = 300ms$)

Na drugim trzecim iteracji podobnie jak przy przeglądzie zupełnym nie został spełniony warunek minimalnego poprawnego rozpoznawania na poziomie 90%.

Czwarta iteracja ($T = 400ms$)

Analiza odległości reprezentantów klas z grupy G_2 została przedstawiona w tabelach 4.10 oraz 4.11. Dla wyliczonych statystyk został wyznaczony ranking klas. Wyniki zostały zaprezentowane w tabeli 4.12.

Zgodnie z otrzymanymi danymi rankingowymi dla klas z grupy G_2 (tab. 4.12) klasa C_4 jest w największej odległości od pozostałych klas. Podział na kolejne podgrupy zostaje przeprowadzony w następujący sposób

$$\begin{cases} G_{21} = \{C_4\} \\ G_{22} = \{C_2, C_3, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}\} \end{cases} \quad (4.16)$$

Średnia dokładność rozpoznawania zostaje przeprowadzona na poziomie 92%. Warunek konieczny zostaje spełniony.

Podział ponownie został wykonany w taki sam sposób jak w przypadku przeglądu zupełnego. Węzeł drzewa decyzyjnego został zaprezentowany na rysunku 4.18.

Tabela. 4.10: Odległości między klasami dla grupy G_2

C_i	C_j	$d(C_i, C_j)$								
2	3	0.100831		7	8	0.223002		5	8	0.269744
6	9	0.127207		3	10	0.224841		3	4	0.281677
10	11	0.13267		6	7	0.227455		3	8	0.291438
5	7	0.138321		4	6	0.22781		7	11	0.297664
8	10	0.143182		3	6	0.228723		2	8	0.297692
9	10	0.143577		6	8	0.232616		3	5	0.301187
9	11	0.14554		2	4	0.238906		5	11	0.305283
8	11	0.172018	...	2	11	0.24726	...	4	9	0.308871
6	11	0.184236		2	10	0.248732		2	7	0.313306
5	6	0.18535		3	9	0.251006		3	7	0.321192
6	10	0.190294		4	5	0.256794		4	7	0.351647
8	9	0.203972		7	9	0.25983		4	10	0.352056
2	6	0.217109		5	9	0.261165		4	11	0.355492
3	11	0.218763		5	10	0.262147		4	8	0.40933
7	10	0.222896		2	9	0.265885				
				2	5	0.266595				

Tabela. 4.11: Statystyki odległości dla grupy G_2

Klasa	d_i^{min}	Klasa	d_i^{max}	Klasa	d_i	Klasa	d_i^{std}
2	0.100831	6	0.232616	6	0.202311	6	0.0325182
3	0.100831	5	0.305283	10	0.213377	5	0.0508925
6	0.127207	9	0.308871	9	0.218561	2	0.0576917
9	0.127207	2	0.313306	11	0.228769	4	0.0585726
10	0.13267	3	0.321192	2	0.244035	9	0.0618955
11	0.13267	7	0.351647	3	0.246629	3	0.062022
5	0.138321	10	0.352056	8	0.249221	7	0.0623504
7	0.138321	11	0.355492	5	0.249621	10	0.0666068
8	0.143182	4	0.40933	7	0.261701	11	0.0733845
4	0.22781	8	0.40933	4	0.309176	8	0.0748353

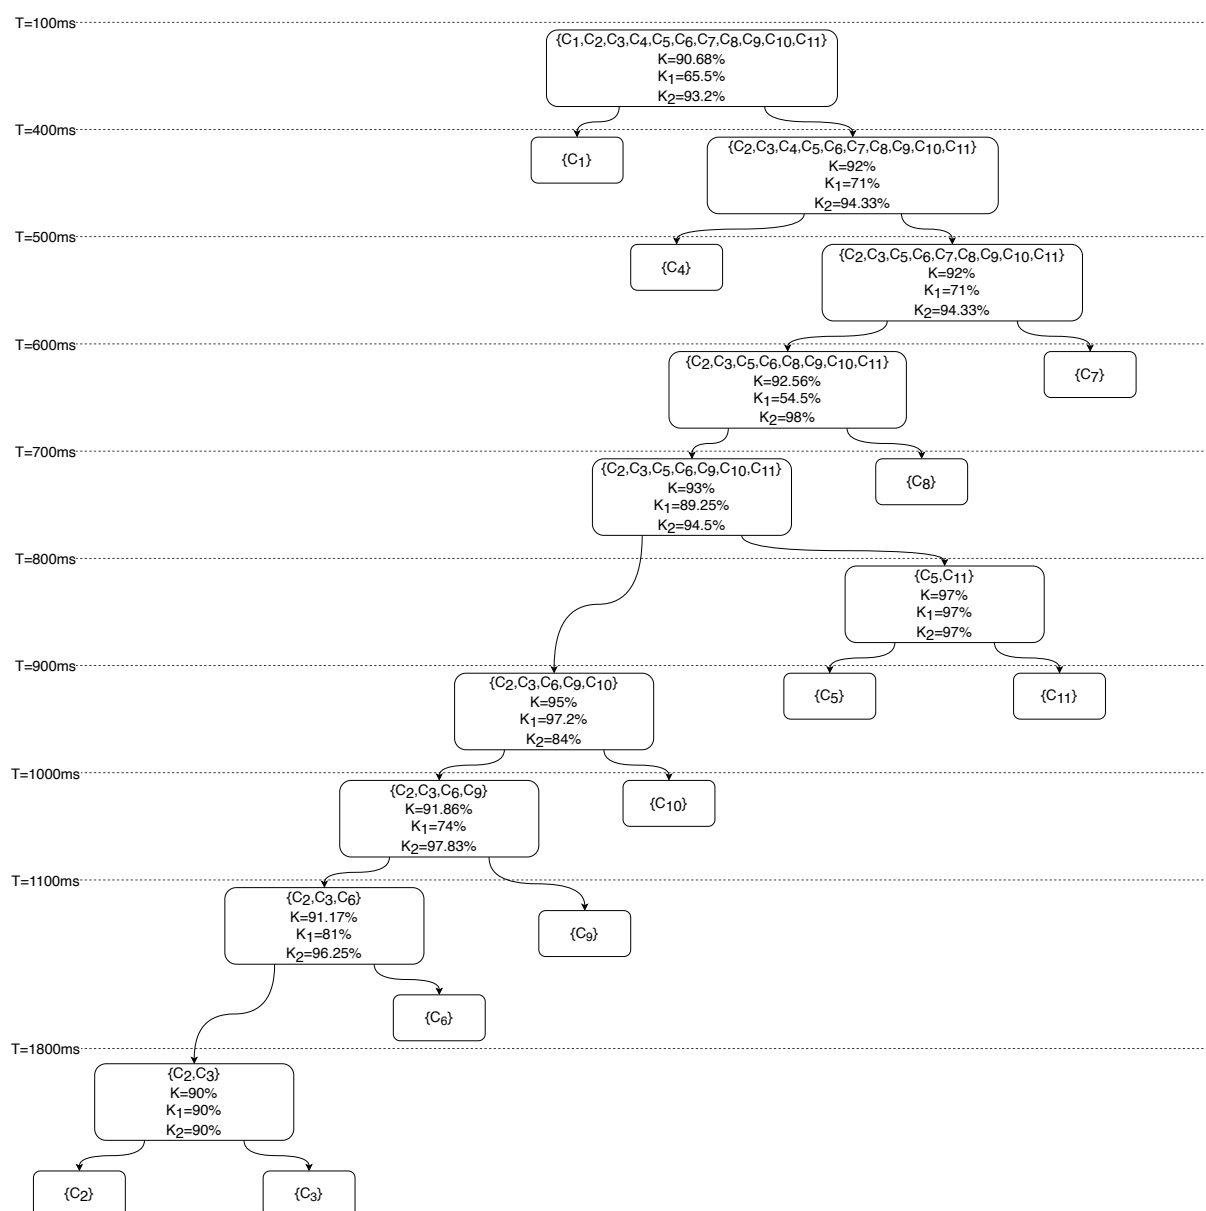
Tabela. 4.12: Ranking odległości dla G_2

C_i	p_i
6	5
2	10
9	10
3	13
10	14
5	17
11	18
7	23
8	26
4	29

Kolejne iteracja

Kolejne iteracje zostają przeprowadzone analogicznie do pierwszych czterech. Warunkiem koniecznym zaakceptowania podziału klas jest średnia wartość rozpoznawania na poziomie conajmniej 90%. W przypadku, kiedy poziom rozpoznawania nie osiągnie zakładanej wartości, a algorytm dojdzie do końcowej iteracji, wybierany jest etap, kiedy rozpoznawanie było największe.

Konstrukcja drzewa decyzyjnego dla klasyfikacji wieloetapowej została zaprezentowana na rysunku 4.20.



Rysunek 4.20: Diagram rozpoznawania wieloetapowego otrzymanego przy pomocy analizy statystyki dla progu akceptacji na poziomie 90%

4.6.4 Dyskusja

Badania zostały podzielone na trzy części, które kolejno dotyczyły:

- analizy informacji w sygnale w zależności od jego długości,
- budowy drzewa decyzyjnego na potrzeby rozpoznawania wieloetapowego przy pomocy przeglądu zupełnego,
- budowy drzewa decyzyjnego na potrzeby rozpoznawania wieloetapowego przy pomocy analizy statystyki reprezentantów klas.

Wszystkie badania, jakie zostały wykonane zostały przeprowadzone z wykorzystaniem 5-cio krotnej walidacji krzyżowej. Etap klasyfikacji został przeprowadzony z wykorzystaniem algorytmu 10-NN.

W pierwszej części doświadczenia, zostało zbadane, która z wykorzystanych metod ekstrakcji daje najlepsze wyniki w zależności od długości sygnału z którego pozyskiwane są cechy do dalszej analizy. Spośród różnego rodzaju metod zostały wybrane takie, które wyznaczają charakterystyczne dla badanego sygnału cechy w dziedzinie czasu i częstotliwości.

W pierwszej kolejności sygnał został podzielony na segmenty o długości wynoszącej odpowiednio T_S (wzór 4.4). Wszystkie długości ze zbioru odnoszą się do sygnału liczonego od początku jego trwania. Wyniki dla sygnału o rosnącej długości zostały zaprezentowane na rysunku 4.9. Wspólną cechą poprawności rozpoznawania (niezależnie od wybranej metody ekstrakcji cech) jest jej wzrost wraz ze wzrostem długości sygnału. Spośród wszystkich zastosowanych metod ekstrakcji najlepsza okazała się krótkoczasowa transformacja Fouriera (STFT). Spośród metod czasowych najlepsza okazała się średnia wartość absolutna (MAV).

W drugim etapie sygnał ponownie został podzielony na segmenty o długości wynoszącej odpowiednio T_S (wzór 4.4). Dodatkowo sygnał elektromiograficzny został podzielony na 100ms odcinki. Otrzymane 100ms odcinki zostały poddane ekstrakcji niezależnie od siebie. Otrzymane wyniki zostały zaprezentowane na rysunku 4.10.

Wyniki otrzymane przy pomocy niepodzielonego sygnału i podzielonego dodatkowo na segmenty o długości 100ms zostały ze sobą porównane na rysunku 4.11. Każda z metod została przeanalizowana z osobna. Zastosowanie podziału sygnału na segmenty poprawiło poziom poprawnego rozpoznawania dla wszystkich metod ekstrakcji poza krótkoczasową transformacją Fouriera. W przypadku metod czasowych, takich jak np. odchylenie standardowe (STD), długość obwiedni (WFL), średnia kwadratowa (RMS)

poziom poprawnego rozpoznawania dla sygnału o długości $2000ms$ poprawił się o ponad 10%.

W kolejnym kroku został zbadany wpływ połączenia zbioru cech otrzymanej przy pomocy krótkoczasowej transformacji Fouriera z każdą z metod czasowych. Otrzymane wyniki zostały zaprezentowane na rysunku 4.12. Każdorazowo dodanie cech otrzymanych przy pomocy krótkoczasowej transformacji Fouriera do cech otrzymanych przy pomocy metod czasowych poprawił poziom rozpoznawania w stosunku do samych metod czasowych.

Do dalszych badań została wytypowana kombinacja metod krótkoczasowa transformacja Fouriera z pełnej długości sygnału i średnia wartość absolutna z sygnału podzielonego na $100ms$ segmenty czasowe jako metody ekstrakcji cech. Etap selekcji zostaje pominięty. Jako model klasyfikatora ponownie został wybrany algorytm k najbliższych sąsiadów z wartością parametru $k = 10$.

Budowa drzewa decyzyjnego na potrzeby klasyfikacji wieloetapowej została przeprowadzona przy pomocy dwóch algorytmów. Pierwszym z nich jest przegląd zupełny. Metoda ta przewiduje sprawdzenie wszystkich możliwych kombinacji podzielenia grupy klas na podgrupy kolejno w czasie T_S (wzór 4.4). Po wytypowania klas należących do podgrup G_{i1} i G_{i2} zostaje przeprowadzony proces walidacji krzyżowej z 5-cio krotnym podziałem. Dla badanej długości sygnału wybrany zostaje taki podział klas, że średnia wartość rozpoznawania ruchów do jednej z grup G_{i1} i G_{i2} jest największa. Jeżeli wartość ta wynosi co najmniej 90% podział zostaje przyjęty jako kolejny węzeł drzewa. Drzewo zostaje w pełni zbudowane, kiedy wszystkie końcowe klasy znajdują się w liściach drzewa. Przykładowy podział w węźle na dwie podgrupy został przedstawiony na rysunku 4.13.

Wyniki dla przeglądu zupełnego zostały przedstawione na rysunku 4.19. Zgodnie z otrzymanymi danymi pierwszy podział klas na podgrupy został przeprowadzony już po $100ms$ z dokładnością poprawnego rozpoznania na poziomie 90.68%.

Dla metody analizy statystyki warunki podziału klas na G_{i1} i G_{i2} są takie same jak w przypadku przeglądu zupełnego. Różnicą pomiędzy dwoma podejściami jest algorytm podziału klas na G_{i1} i G_{i2} . W przypadku analizy statystyki wybierana jest taka klasa (bądź klasy), które zgodnie z przyjętym rankingiem osiągają największą punktację. Zgodnie z przyjętymi założeniami klasa taka w największym stopniu jest odległa od pozostałych. Zostaje więc wybrana do G_{i1} . Pozostałe klasy zostają dodane do G_{i2} . Jeżeli przy założonym podziale średnia wartość rozpoznawania nie jest mniejsza niż 90%, podział

zostaje wybrany do węzła drzewa. Przykładowy podział w węźle na dwie podgrupy został przedstawiony na rysunku 4.13.

Wyniki dla analizy statystyki zostały przedstawione na rysunku 4.20. Zgodnie z otrzymanymi danymi pierwszy podział klas na podgrupy ponownie został przeprowadzony już po $100ms$ z dokładnością poprawnego rozpoznania na poziomie 90.68% .

Otrzymane wyniki zostały sprawdzone testem t -Studenta. Dla doświadczenia zostały postawione dwie hipotezy:


H_0 : średnia wartość rozpoznawania a_0 jest większa, bądź równa 0.90 ($a \geq a_0$),

H_1 : średnia wartość rozpoznawania a_0 jest mniejsza od 0.90 ($a < a_0$).

Dla każdej kombinacji podziału klas zostało przeprowadzonych 30 niezależnych pomiarów.

Wszystkie wyniki z badań dla których wyniki przedstawiono na rysunkach 4.19 oraz 4.20 zostały potwierdzone na poziomie istotności 0.05 .

Wyniki analizy dla dynamicznej transformacji czasowej (DTW) zostały zaprezentowane na rysunku 4.21.



Rysunek 4.21: Czas wykonywania dynamicznej transformacji czasowej w zależności od długości sygnału

Algorytm został opisany w rozdziale 3.3. Podejście to jest bardzo dobrym rozwiązaniem w przypadku braku wiedzy o długości rozpoznawanego sygnału, co ma miejsce w przypadku m.in. rozpoznawania mowy (prędkość mówienia), czy również rozpoznawania

sygnałów elektromiograficznych (prędkość wykonywania ruchu). Jak pokazały badania w przypadku rozwiązywanego problemu DTW jest zbyt wolnym algorytmem. Czas potrzebny na wykonanie pojedynczego porównania dwóch sygnałów został przedstawiony na rysunku 4.21. W przypadku sygnału z pojedynczego kanału czas, jaki był potrzebny na jedno porównanie wynosił ponad 14s.

Rozdział 5

Przyszłe badania

Dalsze badania zostaną nakierowane na połączenie koncepcji sekwencyjnego rozpoznawania z informacjami z rękawicy pomiarowej o posturze dłoni podczas wykonywania chwytów. Baza danych została opisana w rozdziale 4.3.4. W dotychczasowym podejściu klasyfikacja przeprowadzana jest ostatecznie do jednej z wcześniej zdefiniowanych klas. Zastosowanie pomiarów z rękawicy sensorycznej pozwoli na zaprojektowanie systemu decyzyjnego, który przyporządkowuje badany sygnał do konfiguracji dłoni w założonym przedziale, np.:

- konfiguracja 1: zgięcie palca od 0^0 do 30^0 ,
- konfiguracja 2: zgięcie palca od 30^0 do 60^0 ,
- konfiguracja 3: zgięcie palca od 60^0 do 90^0 .

Konfiguracje dla kolejnych palców dłoni rozpoznawane są niezależnie od siebie. Kombinacja wszystkich konfiguracji palców pozwoli na wykonywanie złożonych chwytów dłoni. Nie będzie też potrzeby wcześniejszego definiowania repertuaru chwytów. Każdy użytkownik robotycznej protezy, wyposażonej we wspomniane sterowanie decyzyjne, będzie mógł dopasować ruchy do własnych potrzeb.

Na dokładność klasyfikacji wpływa rodzaj sygnału wykorzystywany w procesie rozpoznawania. W dalszych rozważaniach zostanie uwzględniony sygnał mechanomiograficzny zarejestrowany na powierzchni przedramienia. Jak pokazują badania fuzja sygnału elektromiograficznego i mechanomiograficznego ma pozytywny wpływ na niezawodność systemu klasyfikacji ruchów [88].

Rozdział 6

Podsumowanie

Proces rozpoznawania biosygnarów jest bardzo złożonym zagadnieniem. Końcowy wynik procesu, czyli sterowanie bioprotezą ręki nie jest pojedynczym, dobrze określonym problemem, lecz raczej zbiorem wielu różnych problemów, które wynikają m.in. z:

- ze specyfiki detekcji intencji człowieka (interfejs człowiek proteza),
- własności kinematyki (i dynamiki) protezy,
- interakcji z chwytanymi obiektami,
- wykorzystania informacji o interakcji do sterowania chwytem (sprzężenie zwrotne),
- symulacji podstawowych wrażeń czuciowych dotyku, nacisku, poślizgu (interfejs proteza-człowiek).

Problemy składowe towarzyszące sterowaniu bioprotezą występują w różnych miejscach procesu sterowania. Są one spotykane na określonych poziomach jego struktury i na określonych etapach jego realizacji. Są one modelowane i rozwiązywane w różny sposób. Wśród poziomów procesu sterowania bioprotezą możemy wyróżnić:

- a) sterowanie decyzyjne,
- b) sterowanie kinematyczne,
- c) pomiar stanu protezy i interakcji proteza-obiekt,
- d) przekaz czucia tego stanu do człowieka.

Niniejsza praca została poświęcona problemowi sterowania decyzyjnego. W odróżnieniu od klasycznego podejścia zostało zaproponowane rozwiązanie, w którym proces sterowania zostaje przeprowadzony przed końcem rejestracji sygnału o pełnej długości. Sygnał

taki jest potrzebny, żeby jednoznacznie zaklasyfikować intencję ruchu do jednej z klas końcowych.

Przeprowadzone badania w rozdziale 4.6 potwierdziły możliwość wcześniejszego rozpoczęcia procesu klasyfikacji intencji ruchów. Zastosowanie grupowania pojedynczych klas w większe zbiory pozwala na wstępną analizę przynależności pomiarów. Kolejne iteracje pozwalają na coraz to precyzyjniejszą klasyfikację poprzez sukcesywne dzielenie zbioru klas na coraz to mniejsze podzbiory i eliminację niepasujących klas. Ponadto z założenia działania algorytmu w rzeczywistych warunkach, kolejne iteracje zostają przeprowadzane po upływie wyznaczonego segmentu czasu. Stąd też na podstawie otrzymanych danych jednoznacznie wynika, że im dalsza iteracja, tym dłuższy i bogatszy w informacje jest sygnał pomiarowy.

Celem badań było pokazanie możliwości rozpoczęcia procesu rozpoznawania sygnału elektromiograficznego przed pełnym zakończeniem akwizycji sygnału pojedynczego pomiaru.

Dodatkową wartością płynącą z badań jest informacja o klasach, które były najczęściej błędnie klasyfikowane między sobą. W takim przypadku należy przeprowadzić dalszą analizę mającą na celu zidentyfikowanie przyczyny błędnego przyporządkowania. Prawdopodobnym jest, że klasy te są do siebie bardzo podobne (w sensie wektora cech reprezentującego daną klasę) i możliwe jest pominięcie jednej dla wzrostu poziomu poprawnego etykietowania.

Zaprezentowane badania stanowią wyjście do dalszej analizy sygnałów biologicznych (a w szczególności elektromiograficznych i mechanomiograficznych) we wczesnej fazie akwizycji dla potrzeb sterowania robotyczną protezą dłoni.

Każdorazowo dla badania analizy statystycznej testem studenta w pierwszej kolejności rozkład badany był testem Shapiro-Wilka. Celem badania było sprawdzenie, czy rozkład danych jest rozkładem normalnym.

Dla testów były stawiane dwie hipotezy:

H_0 : próba pochodzi z populacji o rozkładzie normalnym,

H_1 : próba nie pochodzi z populacji o rozkładzie normalnym.

Dodatkowo został przeprowadzony test sprawdzający wpływ zwielokrotnienia etapu ekstrakcji i klasyfikacji cech na długość wykonywania procesu rozpoznawania. Badanie zostało przeprowadzone dla 50000 tysięcy przypadków. Średnia długość pojedynczego cyklu ekstrakcja, klasyfikacja trwała $1.5ms$. Dla testu t Studenta zostały postawione dwie hipotezy:

H_0 : średnia długość trwania etapu ekstrakcji i klasyfikacji dla pojedynczego pomiaru z ośmiu kanałów jest mniejsza, bądź równa $1.5ms$,

H_1 : średnia długość trwania etapu ekstrakcji i klasyfikacji dla pojedynczego pomiaru z ośmiu kanałów jest większa od $1.5ms$.

Dla tak postawionego zadania została potwierdzona hipoteza H_0 na poziomie istotności wynoszącym 0.01.

W przypadku skonstruowanego drzewa decyzyjnego z dziesięcioma węzłami decyzyjnymi łączny czas wykonywania się algorytmów uczenia maszynowego dla zaproponowanych metod wynosi $15ms$. Pojedyncze przekształcenie trwające $1.5ms$ można uznać za spełniające wymogi. Czas ten jest zdecydowanie krótszy od czasu trwania pojedynczego pomiaru dla ustalonych $100ms$.

Co więcej dzięki zaproponowanemu podejściu klasyfikacji wieloetapowej początkowy ruch protezy można zacząć wykonywać już po około $100ms$.

Spis rysunków

1.1	Liczba amputacji urazowych w kolejnych latach.	6
1.2	Grupa przednia mięśni przedramienia [21]	9
1.3	Grupa tylna mięśni przedramienia [21]	10
1.4	Grupa boczna mięśni przedramienia [21]	11
1.5	Przykładowy sygnał elektromiograficzny zarejestrowany na powierzchni przedramienia i jego widmo	13
3.1	Klasyczny proces rozpoznawania.	20
3.2	Sygnały przykładowe okna Hanna (a) i Gaussa (b).	24
3.3	Spektrogram wybranego sygnału elektromiograficznego	25
3.4	Schemat działania algorytmów należących do grupy filtrów [52]	27
3.5	Schemat działania algorytmów należących do grupy wrapperów [52]	29
3.6	Diagram procesu sekwencyjnego rozpoznawania	34
3.7	Schemat przetwarzania z zastosowaniem DTW	38
3.8	DTW - przykładowa ścieżka dla różnych sygnałów elektromiograficznych reprezentujących ten sam ruch	40
3.9	DTW - porównanie dwóch różnych sygnałów elektromiograficznych reprezentujących ten sam ruch	41
3.10	Rozkład t-studenta dla wybranych wartości liczności próby	43
4.1	System pomiarowy zaprojektowany na Politechnice Wrocławskiej [28]	46
4.2	Widok sensora zespolonego [28, 86]	46
4.3	Opaska The Myo [88]	47
4.4	Klasyczny zestaw ruchów [92]	48
4.5	Rozmieszczenie elektrod na przedramieniu [28]	49
4.6	Chwyty dla których został przeprowadzony eksperyment [28, 86]	53
4.7	Rękawica pomiarowa z czujnikami zgięcia	55
4.8	Dokładność rozpoznawania w zależności od wartości parametru k dla algorytmu kNN	57

4.9	Poprawność rozpoznawania w zależności od długości sygnału	65
4.10	Poprawność rozpoznawania w zależności od długości sygnału dla sygnału wstępnie podzielonego na segmenty o długości $100ms$	66
4.11	Porównanie poprawności rozpoznawania dla sygnału oryginalnego i podzielonego na segmenty	68
4.12	Porównanie poprawności rozpoznawania dla sygnału oryginalnego z metody czasowej pozyskiwania cechy i podzielonego na segmenty sygnału poddanego STFT	69
4.13	Podział klas z grupy G na G_1 i G_2	73
4.14	Macierz błędu dla klas z grupy G	74
4.15	Macierz błędu dla klas z grupy G_2	75
4.16	Macierz błędu dla klas z grupy G_2	76
4.17	Macierz błędu dla klas z grupy G_2	76
4.18	Podział klas z grupy G_2 na G_{21} i G_{22}	77
4.19	Diagram rozpoznawania wieloetapowego otrzymanego przy pomocy przeglądu zupełnego dla progu akceptacji na poziomie 90%	78
4.20	Diagram rozpoznawania wieloetapowego otrzymanego przy pomocy analizy statystyki dla progu akceptacji na poziomie 90%	84
4.21	Czas wykonywania dynamicznej transformacji czasowej w zależności od długości sygnału	87

Spis tablic

1.1	Grupa przednia mięśni przedramienia	9
1.2	Grupa tylna mięśni przedramienia	10
1.3	Grupa boczna mięśni przedramienia	11
1.4	Zestawienie różnego typu sygnałów o charakterze biologicznym.	12
4.1	Przyporządkowanie modalności i kanałów do sondy pomiarowej	54
4.2	Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji	60
4.3	Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji oraz metodą sekwencyjnej selekcji wstecznej dla 7 cech	60
4.4	Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji oraz współczynnikiem Fishera dla 7 cech	61
4.5	Dokładność klasyfikacji dla wybranych algorytmów ekstrakcji i klasyfikacji oraz eliminacją po wariancji dla 7 cech	61
4.6	Wyniki klasyfikacji wieloetapowej dla przeglądu zupełnego i warunku na średnią wartość rozpoznawania nie mniejszą od 90%	79
4.7	Odległości między klasami dla grupy G	81
4.8	Statystyki odległości dla grupy G	81
4.9	Ranking odległości dla G	82
4.10	Odległości między klasami dla grupy G_2	83
4.11	Statystyki odległości dla grupy G_2	83
4.12	Ranking odległości dla G_2	83
6.1	Przegląd zupełny pierwszej iteracji	109

Bibliografia

- [1] Courtney Medynski, Beng Eit, and Bruce Bsc. Bebionic prosthetic design. *Proc MyoElectric Controls/Powered Prosthetics Symp*, 2011.
- [2] Bartjan Maat, Gerwin Smit, Dick Plettenburg, and Paul Breedveld. Passive prosthetic hands and tools: A literature review. *Prosthetics and Orthotics International*, 42(1):66–74, March 2017.
- [3] Jan Kędzierski and Mariusz Janiak. Budowa robota społecznego flash. In *Prace Naukowe Politechniki Warszawskiej. Elektronika*, volume z. 182, t. 2, pages 681–694, 2012.
- [4] Md Assad-Uz-Zaman, Md Rasedul Islam, Suruz Miah, and Mohammad H Rahman. NAO robot for cooperative rehabilitation training. *Journal of Rehabilitation and Assistive Technologies Engineering*, 6, January 2019.
- [5] Simon DiMaio, Mike Hanuschik, and Usha Kreaden. The da vinci surgical system. In *Surgical Robotics*, pages 199–217. Springer US, November 2010.
- [6] Z. Nawrat and Pawel Kostka. Robin heart surgery robotic system. challenges in mechanical construction, control system and stuff training before first clinical application. *Archive of Mechanical Engineering*, 61, 03 2014.
- [7] Maciej Trojnacki. *Mobilne roboty lądowe w służbie bezpieczeństwa i obronności – wybrane rozwiązania i prace badawcze*. 01 2014.
- [8] Departament Pracy GUS. Wypadki przy pracy w 2011 r. *Główny Urząd Statystyczny*, 2012.
- [9] Departament Badań Demograficznych i Rynku Pracy GUS. Wypadki przy pracy w 2012 r. *Główny Urząd Statystyczny*, 2013.
- [10] Departament Badań Demograficznych i Rynku Pracy GUS. Wypadki przy pracy w 2013 r. *Główny Urząd Statystyczny*, 2014.

- [11] Departament Badań Demograficznych i Rynku Pracy GUS. Wypadki przy pracy w 2014 r. *Główny Urząd Statystyczny*, 2015.
- [12] Departament Badań Demograficznych i Rynku Pracy GUS. Wypadki przy pracy w 2015 r. *Główny Urząd Statystyczny*, 2016.
- [13] Departament Badań Demograficznych i Rynku Pracy GUS. Wypadki przy pracy w 2016 r. *Główny Urząd Statystyczny*, 2017.
- [14] Ośrodek Statystyki Warunków Pracy Urząd Statystyczny w Gdańsku. Wypadki przy pracy w 2017 r. *Główny Urząd Statystyczny*, 2018.
- [15] Ośrodek Statystyki Warunków Pracy Urząd Statystyczny w Gdańsku. Wypadki przy pracy w 2018 r. *Główny Urząd Statystyczny*, 2019.
- [16] Ośrodek Statystyki Warunków Pracy Urząd Statystyczny w Gdańsku. Wypadki przy pracy w 2019 r. *Główny Urząd Statystyczny*.
- [17] Joseph Belter, Jacob Segil, Aaron Dollar, and Richard Weir. Mechanical design and performance specifications of anthropomorphic prosthetic hands: A review. *Journal of rehabilitation research and development*, 50:599–618, 08 2013.
- [18] Peter J. Kyberd. Assessment of functionality of multifunction prosthetic hands. *JPO Journal of Prosthetics and Orthotics*, 29(3):103–111, July 2017.
- [19] T. R. Farrell and R. F. Weir. The optimal controller delay for myoelectric prostheses. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 15(1):111–118, 2007.
- [20] Adam Bochenek and Michał Reicher. *Anatomia człowieka Tom 1*. PZWL Wydawnictwo Lekarskie.
- [21] R. Pabst and A. H. Weiglen. *Sobotta - Atlas of Human Anatomy*.
- [22] Igor Zubrycki and Grzegorz Granosik. Evaluation of simple microphone-based mechanomyography (MMG) probe sets for hand stiffness classification. *Journal of Automation, Mobile Robotics and Intelligent Systems*, 13(2):28–39, September 2019.
- [23] Andrzej Wołczowski and Rafał Zdunek. Electromyography and mechanomyography signal recognition: Experimental analysis using multi-way array decomposition methods. *Biocybernetics and Biomedical Engineering*, 37(1):103–113, 2017.
- [24] Haller Piroska and Szalai Janos. Specific movement detection in EEG signal using time-frequency analysis. In *2008 First International Conference on Complexity and*

- Intelligence of the Artificial and Natural Complex Systems. Medical Applications of the Complex Systems. Biomedical Computing.* IEEE, November 2008.
- [25] Carlo De Luca. *Encyclopedia of Medical Devices and Instrumentation.* John Wiley & Sons, Inc., April 2006.
- [26] Silviya Angelova, Simeon Ribagin, Rosiza Raikova, and Ivanka Veneva. Power frequency spectrum analysis of surface emg signals of upper limb muscles during elbow flexion – a comparison between healthy subjects and stroke survivors. *Journal of Electromyography and Kinesiology*, 38, 10 2017.
- [27] Haitham M. Al-Angari, Gunter Kanitz, Sergio Tarantino, and Christian Cipriani. Distance and mutual information methods for EMG feature and channel subset selection for classification of hand movements. *Biomedical Signal Processing and Control*, 27:24–31, May 2016.
- [28] Andrzej Wołczowski, Michał Błędowski, and Jerzy Witkowski. The system for EMG and MMG signals recording for the bioprosthetic hand control. *Journal of Automation, Mobile Robotics & Intelligent Systems*, 11(3):22–29, November 2017.
- [29] M. Mironovova and J. Bíla. Fast fourier transform for feature extraction and neural network for classification of electrocardiogram signals. In *2015 Fourth International Conference on Future Generation Communication Technology (FGCT)*, pages 1–6, 2015.
- [30] E. Sejdic, I Djurovic, and J. Jiang. Time-frequency feature representation using energy concentration: An overview of recent advances. *Digital Signal Processing*, pages 153–183, 2007.
- [31] E. F. Shair, S. A. Ahmad, M. H. Marhaban, S. B. Mohd Tamrin, and A. R. Abdullah. EMG processing based measures of fatigue assessment during manual lifting. *BioMed Research International*, 2017:1–12, 2017.
- [32] Zeeshan O Khokhar, Zhen G Xiao, and Carlo Menon. Surface EMG pattern recognition for real-time control of a wrist exoskeleton. *BioMedical Engineering OnLine*, 9(1):41, 2010.
- [33] Sara Abbaspour, Maria Lindén, Hamid Gholamhosseini, Autumn Naber, and Max Ortiz-Catalan. Evaluation of surface EMG-based recognition algorithms for decoding hand movements. *Medical & Biological Engineering & Computing*, 58(1):83–100, November 2019.

- [34] M. Zardoshti-Kermani, B.C. Wheeler, K. Badie, and R.M. Hashemi. EMG feature evaluation for movement control of upper extremity prostheses. *IEEE Transactions on Rehabilitation Engineering*, 3(4):324–333, 1995.
- [35] Xueyan Tang, Yunhui Liu, Congyi Lv, and Dong Sun. Hand motion classification using a multi-channel surface electromyography sensor. *Sensors*, 12(2):1130–1147, January 2012.
- [36] J. Kilby and K. Prasad. Analysis of surface electromyography signals using discrete fourier transform sliding window technique. *International Journal of Computer Theory and Engineering*, pages 321–325, 2013.
- [37] Sidharth Pancholi and Amit M. Joshi. Time derivative moments based feature extraction approach for recognition of upper limb motions using EMG. *IEEE Sensors Letters*, 3(4):1–4, April 2019.
- [38] T. N. S. T. Zawawi, A. R. Abdullah, E. F. Shair, I. Halim, and O. Rawaida. Electromyography signal analysis using spectrogram. In *2013 IEEE Student Conference on Research and Development*. IEEE, December 2013.
- [39] Neta Rabin, Maayan Kahlon, Sarit Malayev, and Anat Ratnovsky. Classification of human hand movements based on EMG signals using nonlinear dimensionality reduction and data fusion techniques. *Expert Systems with Applications*, 149:113281, July 2020.
- [40] An-Chih Tsai, Jer-Junn Luh, and Ta-Te Lin. A novel STFT-ranking feature of multi-channel EMG for motion pattern recognition. *Expert Systems with Applications*, 42(7):3327–3341, May 2015.
- [41] A.N. Mucciardi and E.E. Gose. A comparison of seven techniques for choosing subsets of pattern recognition properties. *IEEE Transactions on Computers*, C-20(9):1023–1031, September 1971.
- [42] Andrzej Wołczowski and Krzysztof Krzysztoforski. Artificial hand control via emg signal classification - experimental investigation of algorithms. In Krzysztof Tchoń, editor, *Progress in robotics*, pages 97–122. Wydawnictwa Komunikacji i Łączności, Warszawa, 2008.
- [43] Janez Brank, Dunja Mladenić, Marko Grobelnik, Huan Liu, Dunja Mladenić, Peter A. Flach, Gemma C. Garriga, Hannu Toivonen, and Hannu Toivonen. Feature selection. In *Encyclopedia of Machine Learning*, pages 402–406. Springer US, 2011.

- [44] Luis Talavera. An evaluation of filter and wrapper methods for feature selection in categorical clustering. In *Lecture Notes in Computer Science*, pages 440–451. Springer Berlin Heidelberg, 2005.
- [45] Nuhu Ibrahim, H.A. Hamid, Shuzlina Rahman, and Simon Fong. Feature selection methods: Case of filter and wrapper approaches for maximising classification accuracy. *Pertanika Journal of Science and Technology*, 26:329–340, 01 2018.
- [46] Mohamad Morovvat and Alireza Osareh. An ensemble of filters and wrappers for microarray data classification. *Machine Learning and Applications: An International Journal*, 3(2):01–17, June 2016.
- [47] R. Bellman and R. Kalaba. On adaptive control processes. *IRE Transactions on Automatic Control*, 4(2):1–9, 1959.
- [48] Jaroslaw Gramacki, Artur Gramacki, and Uniwersytet Zielonogórski. Redukcja wymiarowości oraz wizualizacja danych wielowymiarowych z wykorzystaniem projektu r. 03 2021.
- [49] Kevin Beyer, Jonathan Goldstein, Raghu Ramakrishnan, and Uri Shaft. When is nearest neighbor meaningful? In *Lecture Notes in Computer Science*, pages 217–235. Springer Berlin Heidelberg, 1999.
- [50] R. B. Marimont and M. B. Shapiro. Nearest neighbour searches and the curse of dimensionality. *IMA Journal of Applied Mathematics*, 24(1):59–70, 1979.
- [51] Isabelle Guyon and Andre Elisseeff. An introduction to variable and feature selection. *Journal of Machine Learning Research*, 2003.
- [52] M.A. Hall and G. Holmes. Benchmarking attribute selection techniques for discrete class data mining. *IEEE Transactions on Knowledge and Data Engineering*, 15(6):1437–1447, November 2003.
- [53] Hakan Sporrang, Gunnar Palmerud, and Peter Herberts. Hand grip increases shoulder muscle activity: An EMG analysis with static handcontractions in 9 subjects. *Acta Orthopaedica Scandinavica*, 67(5):485–490, January 1996.
- [54] Quanquan Gu, Z. Li, and Jiawei Han. Generalized fisher score for feature selection. In *UAI*, 2011.
- [55] Jason Van Hulse, Taghi M. Khoshgoftaar, Amri Napolitano, and Randall Wald. Threshold-based feature selection techniques for high-dimensional bioinformatics data. *Network Modeling Analysis in Health Informatics and Bioinformatics*, 1(1-2):47–61, May 2012.

- [56] F.J. Ferri, P. Pudil, M. Hatef, and J. Kittler. Comparative study of techniques for large-scale feature selection. In *Pattern Recognition in Practice IV - Multiple Paradigms, Comparative Studies and Hybrid Systems*, pages 403–413. Elsevier, 1994.
- [57] Shigeo Abe. *Feature Selection and Extraction*, pages 331–341. Springer London, London, 2010.
- [58] DAVID M. DUTTON and GERARD V. CONROY. A review of machine learning. *The Knowledge Engineering Review*, 12(4):341–367, December 1997.
- [59] Padraig Cunningham, Matthieu Cord, and Sarah Jane Delany. Supervised learning. In *Machine Learning Techniques for Multimedia*, pages 21–49. Springer Berlin Heidelberg.
- [60] Debo Cheng, Shichao Zhang, Zhenyun Deng, Yonghua Zhu, and Ming Zong. kNN algorithm with data-driven k value. In *Advanced Data Mining and Applications*, pages 499–512. Springer International Publishing, 2014.
- [61] Kang Soo Kim, Heung Ho Choi, Chang Soo Moon, and Chi Woong Mun. Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions. *Current Applied Physics*, 11(3):740–745, May 2011.
- [62] T. Cover and P. Hart. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1):21–27, January 1967.
- [63] S. Zhang, X. Li, M. Zong, X. Zhu, and R. Wang. Efficient knn classification with different numbers of nearest neighbors. *IEEE Transactions on Neural Networks and Learning Systems*, 29(5):1774–1785, 2018.
- [64] Bernhard E. Boser, Isabelle M. Guyon, and Vladimir N. Vapnik. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory - COLT '92*. ACM Press, 1992.
- [65] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine learning*, 20(3):273–297, 1995.
- [66] M Ihsan, A Kuraesin, Mustakim Mustakim, Gsachmad Daengs, and Ida Bagus Ary Indra Iswara. Electromyography (emg) signal classification for wrist movement using naïve bayes classifier. *Journal of Physics: Conference Series*, 1424:012013, 12 2019.
- [67] David J. Hand and Keming Yu. Idiot’s bayes: Not so stupid after all? *International Statistical Review / Revue Internationale de Statistique*, 69(3):385, December 2001.

- [68] Danuta Knapikowa, Henryk Kordecki, Marek Kurzyński, and Stefan Kwiatkowski. Application of a multistage classifier to the diagnosis of some occupational disease groups. *International Archives of Occupational and Environmental Health*, 53(2):149–155, December 1983.
- [69] M. Bledowski and A. Wolczowski. Method of sequential classification for pre-grouping hand movements classes for fast labeling process of an electromyographic signals. In *2019 IEEE Symposium Series on Computational Intelligence (SSCI)*, pages 3259–3264, 2019.
- [70] Geoffrey I. Webb, Johannes Fürnkranz, Johannes Fürnkranz, Johannes Fürnkranz, Geoffrey Hinton, Claude Sammut, Joerg Sander, Michail Vlachos, Yee Whye Teh, Ying Yang, Dunja Mladeni, Janez Brank, Marko Grobelnik, Ying Zhao, George Karypis, Susan Craw, Martin L. Puterman, and Jonathan Patrick. Decision tree. In *Encyclopedia of Machine Learning*, pages 263–267. Springer US, 2011.
- [71] Marek Kurzynski, Maciej Krysmann, Pawel Trajdos, and Andrzej Wolczowski. Multiclassifier system with hybrid learning applied to the control of bioprosthetic hand. *Computers in Biology and Medicine*, 69:286–297, February 2016.
- [72] Philip H. Swain and Hans Hauska. The decision tree classifier: Design and potential. *IEEE Transactions on Geoscience Electronics*, 15(3):142–147, July 1977.
- [73] Sana Nisar, Akhlaq Ahmed Khan, and Muhammad Younus Javed. A statistical feature based decision tree approach for hand gesture recognition. In *Proceedings of the 6th International Conference on Frontiers of Information Technology - FIT '09*. ACM Press, 2009.
- [74] Ababneh Mohammad, Oqeili Saleh, and Rawan A. Abdeen. Occurrences algorithm for string searching based on brute-force algorithm. *Journal of Computer Science*, 2(1):82–85, January 2006.
- [75] Marek W. Kurzyński. The optimal strategy of a tree classifier. *Pattern Recognition*, 16(1):81–87, January 1983.
- [76] Ivan Dokmanic, Reza Parhizkar, Juri Ranieri, and Martin Vetterli. Euclidean distance matrices: Essential theory, algorithms, and applications. *IEEE Signal Processing Magazine*, 32(6):12–30, November 2015.
- [77] Toni Giorgino. Computing and visualizing dynamic time warping alignments inR: ThedtwPackage. *Journal of Statistical Software*, 31(7), 2009.

- [78] Eamonn J. Keogh and Michael J. Pazzani. Derivative dynamic time warping. In *In First SIAM International Conference on Data Mining SDM'2001*, 2001.
- [79] C. S. Myers and L. R. Rabiner. A comparative study of several dynamic time-warping algorithms for connected-word recognition. *The Bell System Technical Journal*, 60(7):1389–1409, 1981.
- [80] S. Salvador and P. Chan. Fastdtw: Toward accurate dynamic time warping in linear time and space. 2004.
- [81] Dynamic time warping. In *Information Retrieval for Music and Motion*, pages 69–84. Springer Berlin Heidelberg, 2007.
- [82] Yingmin Li, Huiguo Chen, and Zheqian Wu. Dynamic time warping distance method for similarity test of multipoint ground motion field. *Mathematical Problems in Engineering*, 2010:1–12, 2010.
- [83] S. S. Shapiro and M. B. Wilk. An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4):591, December 1965.
- [84] Damir Kalpić, Nikica Hlupić, and Miodrag Lovrić. Student's t-tests. In *International Encyclopedia of Statistical Science*, pages 1559–1563. Springer Berlin Heidelberg, 2011.
- [85] Thomas G. Dietterich. Approximate statistical tests for comparing supervised classification learning algorithms. *Neural Computation*, 10(7):1895–1923, October 1998.
- [86] A. Wołczowski and J. S. Witkowski. Stanowisko badawcze do akwizycji biosygnarów. *Raporty Inst. Inform. Autom. Robot*, 47, 2013.
- [87] Thalmic labs. MYO armband tech specs.
- [88] Michał Błędowski and Andrzej Wołczowski. Determination of the relationship between EMG signals and hand grips using a commercial myo armband. *Journal of Automation, Mobile Robotics and Intelligent Systems*, 13(2):40–47, September 2019.
- [89] M. Geryes, J. Charara, A. Skaiky, A. Mcheick, and J. Girault. A novel biomedical application for the myo gesture control armband. In *2017 29th International Conference on Microelectronics (ICM)*, pages 1–4, 2017.
- [90] A. A.Hidayat, Z. Arief, and D. C. Happyanto. Lovett scaling with flex sensor and myo armband for monitoring finger muscles therapy of post-stroke people. *EMITTER International Journal of Engineering Technology*, 3:60–76, 2015.

- [91] I. Mendez, B. W. Hansen, C. M. Grabow, E. J. L. Smedegaard, N. B. Skogberg, X. J. Uth, A. Bruhn, B. Geng, and E. N. Kamavuako. Evaluation of the myo armband for the classification of hand motions. In *2017 International Conference on Rehabilitation Robotics (ICORR)*, pages 1211–1214, 2017.
- [92] M. Borchardt, Konrad Hartmann, Leymann, Richard Radike, Schlesinger, and Schwiening, editors. *Ersatzglieder und Arbeitshilfen*. Springer Berlin Heidelberg, 1919.
- [93] Andrzej Wołczowski, Michał Błędowski, and Maciej Przydatek. Dane pomiarowe sygnałów emg i mmg z przedramienia,[zbiór, baza danych] dostępny w atlasie zasobów otwartej nauki. licencja: Id-nc-nd, https://azon.e-science.pl/licencje/id-nc-nd_pwr.pdf. data dostępu: 28.05.2020.
- [94] Bruno Clerckx and Claude Oestges. From multi-dimensional propagation to multi-link MIMO channels. In *Mimo Wireless Networks*, pages 29–58. Elsevier, 2013.
- [95] William Ford. Vector and matrix norms. In *Numerical Linear Algebra with Applications*, pages 119–144. Elsevier, 2015.
- [96] Computational methods for optimal compression and reconstruction of random data. In *Mathematics in Science and Engineering*, pages 291–378. Elsevier, 2007.

Dodatki

Tabela. 6.1: Przegląd zupełny pierwszej iteracji

G_1	G_2	K_1 [%]	K_2 [%]	K [%]
{ C_1 }	{ $C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	60.0	93.8	90.73
{ C_2 }	{ $C_1, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	30.0	90.5	85.0
{ C_3 }	{ $C_1, C_2, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	45.5	92.45	88.18
{ C_4 }	{ $C_1, C_2, C_3, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	29.0	92.05	86.32
{ C_5 }	{ $C_1, C_2, C_3, C_4, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	30.5	91.25	85.73
{ C_6 }	{ $C_1, C_2, C_3, C_4, C_5, C_7, C_8, C_9, C_{10}, C_{11}$ }	29.0	93.2	87.36
{ C_7 }	{ $C_1, C_2, C_3, C_4, C_5, C_6, C_8, C_9, C_{10}, C_{11}$ }	26.5	93.85	87.73
{ C_8 }	{ $C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_9, C_{10}, C_{11}$ }	26.5	92.95	86.91
{ C_9 }	{ $C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_{10}, C_{11}$ }	32.0	93.6	88.0
{ C_{10} }	{ $C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{11}$ }	14.5	94.75	87.45
{ C_{11} }	{ $C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}$ }	18.0	95.75	88.68
{ C_1, C_2 }	{ $C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	48.25	83.28	76.91
{ C_1, C_3 }	{ $C_2, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	56.0	85.44	80.09
{ C_1, C_4 }	{ $C_2, C_3, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	55.0	86.61	80.86
{ C_1, C_5 }	{ $C_2, C_3, C_4, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	54.5	85.44	79.82
{ C_1, C_6 }	{ $C_2, C_3, C_4, C_5, C_7, C_8, C_9, C_{10}, C_{11}$ }	49.25	86.61	79.82
{ C_1, C_7 }	{ $C_2, C_3, C_4, C_5, C_6, C_8, C_9, C_{10}, C_{11}$ }	51.75	88.17	81.55
{ C_1, C_8 }	{ $C_2, C_3, C_4, C_5, C_6, C_7, C_9, C_{10}, C_{11}$ }	47.5	86.22	79.18
{ C_1, C_9 }	{ $C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_{10}, C_{11}$ }	48.0	86.44	79.45
{ C_1, C_{10} }	{ $C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{11}$ }	38.25	87.5	78.55
{ C_1, C_{11} }	{ $C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}$ }	43.25	89.33	80.95
{ C_2, C_3 }	{ $C_1, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	54.5	84.78	79.27
{ C_2, C_4 }	{ $C_1, C_3, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	39.5	82.83	74.95
{ C_2, C_5 }	{ $C_1, C_3, C_4, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	36.75	81.17	73.09
{ C_2, C_6 }	{ $C_1, C_3, C_4, C_5, C_7, C_8, C_9, C_{10}, C_{11}$ }	37.75	83.72	75.36
{ C_2, C_7 }	{ $C_1, C_3, C_4, C_5, C_6, C_8, C_9, C_{10}, C_{11}$ }	36.0	84.33	75.55
{ C_2, C_8 }	{ $C_1, C_3, C_4, C_5, C_6, C_7, C_9, C_{10}, C_{11}$ }	32.5	82.56	73.45
{ C_2, C_9 }	{ $C_1, C_3, C_4, C_5, C_6, C_7, C_8, C_{10}, C_{11}$ }	41.25	84.61	76.73
{ C_2, C_{10} }	{ $C_1, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{11}$ }	30.0	85.33	75.27
{ C_2, C_{11} }	{ $C_1, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}$ }	31.75	86.44	76.5
{ C_3, C_4 }	{ $C_1, C_2, C_5, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	46.75	84.89	77.95
{ C_3, C_5 }	{ $C_1, C_2, C_4, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	43.0	83.0	75.73
{ C_3, C_6 }	{ $C_1, C_2, C_4, C_5, C_7, C_8, C_9, C_{10}, C_{11}$ }	44.5	85.67	78.18
{ C_3, C_7 }	{ $C_1, C_2, C_4, C_5, C_6, C_8, C_9, C_{10}, C_{11}$ }	41.5	86.0	77.91
{ C_3, C_8 }	{ $C_1, C_2, C_4, C_5, C_6, C_7, C_9, C_{10}, C_{11}$ }	38.0	84.22	75.82
{ C_3, C_9 }	{ $C_1, C_2, C_4, C_5, C_6, C_7, C_8, C_{10}, C_{11}$ }	41.75	85.17	77.27
{ C_3, C_{10} }	{ $C_1, C_2, C_4, C_5, C_6, C_7, C_8, C_9, C_{11}$ }	34.75	86.83	77.36
{ C_3, C_{11} }	{ $C_1, C_2, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}$ }	39.75	88.67	79.77
{ C_4, C_5 }	{ $C_1, C_2, C_3, C_6, C_7, C_8, C_9, C_{10}, C_{11}$ }	40.75	83.89	76.05
{ C_4, C_6 }	{ $C_1, C_2, C_3, C_5, C_7, C_8, C_9, C_{10}, C_{11}$ }	34.25	84.78	75.59
{ C_4, C_7 }	{ $C_1, C_2, C_3, C_5, C_6, C_8, C_9, C_{10}, C_{11}$ }	38.5	86.72	77.95

{C4, C8}	{C1, C2, C3, C5, C6, C7, C9, C10, C11}	31.25	84.11	74.5
{C4, C9}	{C1, C2, C3, C5, C6, C7, C8, C10, C11}	32.0	84.39	74.86
{C4, C10}	{C1, C2, C3, C5, C6, C7, C8, C9, C11}	26.25	86.33	75.41
{C4, C11}	{C1, C2, C3, C5, C6, C7, C8, C9, C10}	32.25	88.39	78.18
{C5, C6}	{C1, C2, C3, C4, C7, C8, C9, C10, C11}	42.0	85.44	77.55
{C5, C7}	{C1, C2, C3, C4, C6, C8, C9, C10, C11}	43.25	86.72	78.82
{C5, C8}	{C1, C2, C3, C4, C6, C7, C9, C10, C11}	36.5	84.22	75.55
{C5, C9}	{C1, C2, C3, C4, C6, C7, C8, C10, C11}	38.25	84.72	76.27
{C5, C10}	{C1, C2, C3, C4, C6, C7, C8, C9, C11}	25.5	85.11	74.27
{C5, C11}	{C1, C2, C3, C4, C6, C7, C8, C9, C10}	26.0	85.94	75.05
{C6, C7}	{C1, C2, C3, C4, C5, C8, C9, C10, C11}	37.25	87.72	78.55
{C6, C8}	{C1, C2, C3, C4, C5, C7, C9, C10, C11}	36.25	86.5	77.36
{C6, C9}	{C1, C2, C3, C4, C5, C7, C8, C10, C11}	35.25	86.39	77.09
{C6, C10}	{C1, C2, C3, C4, C5, C7, C8, C9, C11}	27.0	87.78	76.73
{C6, C11}	{C1, C2, C3, C4, C5, C7, C8, C9, C10}	27.25	88.56	77.41
{C7, C8}	{C1, C2, C3, C4, C5, C6, C9, C10, C11}	30.75	86.28	76.18
{C7, C9}	{C1, C2, C3, C4, C5, C6, C8, C10, C11}	31.0	86.44	76.36
{C7, C10}	{C1, C2, C3, C4, C5, C6, C8, C9, C11}	23.25	87.94	76.18
{C7, C11}	{C1, C2, C3, C4, C5, C6, C8, C9, C10}	24.25	88.89	77.14
{C8, C9}	{C1, C2, C3, C4, C5, C6, C7, C10, C11}	41.75	87.83	79.45
{C8, C10}	{C1, C2, C3, C4, C5, C6, C7, C9, C11}	37.75	90.17	80.64
{C8, C11}	{C1, C2, C3, C4, C5, C6, C7, C9, C10}	29.75	89.11	78.32
{C9, C10}	{C1, C2, C3, C4, C5, C6, C7, C8, C11}	37.0	90.11	80.45
{C9, C11}	{C1, C2, C3, C4, C5, C6, C7, C8, C10}	34.5	90.28	80.14
{C10, C11}	{C1, C2, C3, C4, C5, C6, C7, C8, C9}	25.25	91.44	79.41
{C1, C2, C3}	{C4, C5, C6, C7, C8, C9, C10, C11}	60.67	76.75	72.36
{C1, C2, C4}	{C3, C5, C6, C7, C8, C9, C10, C11}	55.5	76.38	70.68
{C1, C2, C5}	{C3, C4, C6, C7, C8, C9, C10, C11}	52.83	74.19	68.36
{C1, C2, C6}	{C3, C4, C5, C7, C8, C9, C10, C11}	50.5	75.94	69.0
{C1, C2, C7}	{C3, C4, C5, C6, C8, C9, C10, C11}	51.83	77.56	70.55
{C1, C2, C8}	{C3, C4, C5, C6, C7, C9, C10, C11}	46.67	74.5	66.91
{C1, C2, C9}	{C3, C4, C5, C6, C7, C8, C10, C11}	51.0	76.25	69.36
{C1, C2, C10}	{C3, C4, C5, C6, C7, C8, C9, C11}	42.83	76.81	67.55
{C1, C2, C11}	{C3, C4, C5, C6, C7, C8, C9, C10}	46.17	78.88	69.95
{C1, C3, C4}	{C2, C5, C6, C7, C8, C9, C10, C11}	60.33	78.69	73.68
{C1, C3, C5}	{C2, C4, C6, C7, C8, C9, C10, C11}	57.0	76.25	71.0
{C1, C3, C6}	{C2, C4, C5, C7, C8, C9, C10, C11}	55.0	78.12	71.82
{C1, C3, C7}	{C2, C4, C5, C6, C8, C9, C10, C11}	55.5	79.44	72.91
{C1, C3, C8}	{C2, C4, C5, C6, C7, C9, C10, C11}	50.33	76.38	69.27
{C1, C3, C9}	{C2, C4, C5, C6, C7, C8, C10, C11}	51.33	76.88	69.91
{C1, C3, C10}	{C2, C4, C5, C6, C7, C8, C9, C11}	46.0	78.5	69.64
{C1, C3, C11}	{C2, C4, C5, C6, C7, C8, C9, C10}	51.5	81.38	73.23
{C1, C4, C5}	{C2, C3, C6, C7, C8, C9, C10, C11}	60.33	79.06	73.95
{C1, C4, C6}	{C2, C3, C5, C7, C8, C9, C10, C11}	53.0	78.94	71.86
{C1, C4, C7}	{C2, C3, C5, C6, C8, C9, C10, C11}	58.33	82.06	75.59
{C1, C4, C8}	{C2, C3, C5, C6, C7, C9, C10, C11}	50.67	78.06	70.59
{C1, C4, C9}	{C2, C3, C5, C6, C7, C8, C10, C11}	49.67	77.81	70.14
{C1, C4, C10}	{C2, C3, C5, C6, C7, C8, C9, C11}	45.17	79.75	70.32
{C1, C4, C11}	{C2, C3, C5, C6, C7, C8, C9, C10}	51.33	82.88	74.27
{C1, C5, C6}	{C2, C3, C4, C7, C8, C9, C10, C11}	57.33	79.38	73.36
{C1, C5, C7}	{C2, C3, C4, C6, C8, C9, C10, C11}	60.67	81.75	76.0
{C1, C5, C8}	{C2, C3, C4, C6, C7, C9, C10, C11}	53.33	77.88	71.18
{C1, C5, C9}	{C2, C3, C4, C6, C7, C8, C10, C11}	53.0	77.88	71.09
{C1, C5, C10}	{C2, C3, C4, C6, C7, C8, C9, C11}	43.83	78.06	68.73
{C1, C5, C11}	{C2, C3, C4, C6, C7, C8, C9, C10}	46.33	79.81	70.68
{C1, C6, C7}	{C2, C3, C4, C5, C8, C9, C10, C11}	53.67	81.75	74.09

{C ₁ , C ₆ , C ₈ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	50.17	79.31	71.36
{C ₁ , C ₆ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	48.0	78.62	70.27
{C ₁ , C ₆ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	41.83	79.94	69.55
{C ₁ , C ₆ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	44.17	81.62	71.41
{C ₁ , C ₇ , C ₈ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	49.0	80.0	71.55
{C ₁ , C ₇ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	47.67	79.62	70.91
{C ₁ , C ₇ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	41.83	81.06	70.36
{C ₁ , C ₇ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	44.67	82.94	72.5
{C ₁ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	52.0	80.12	72.45
{C ₁ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	48.67	82.5	73.27
{C ₁ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	45.5	82.12	72.14
{C ₁ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	46.67	81.88	72.27
{C ₁ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	47.17	82.88	73.14
{C ₁ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	40.33	83.94	72.05
{C ₂ , C ₃ , C ₄ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	59.0	77.81	72.68
{C ₂ , C ₃ , C ₅ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	54.17	74.81	69.18
{C ₂ , C ₃ , C ₆ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	56.33	78.25	72.27
{C ₂ , C ₃ , C ₇ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	54.0	78.5	71.82
{C ₂ , C ₃ , C ₈ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	49.33	75.62	68.45
{C ₂ , C ₃ , C ₉ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	55.83	78.19	72.09
{C ₂ , C ₃ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	49.5	79.44	71.27
{C ₂ , C ₃ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	52.83	81.5	73.68
{C ₂ , C ₄ , C ₅ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	48.17	74.12	67.05
{C ₂ , C ₄ , C ₆ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	45.0	75.56	67.23
{C ₂ , C ₄ , C ₇ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	47.5	77.62	69.41
{C ₂ , C ₄ , C ₈ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	40.33	73.81	64.68
{C ₂ , C ₄ , C ₉ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	44.83	75.62	67.23
{C ₂ , C ₄ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	39.33	77.19	66.86
{C ₂ , C ₄ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	43.33	79.5	69.64
{C ₂ , C ₅ , C ₆ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	47.83	75.44	67.91
{C ₂ , C ₅ , C ₇ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	48.33	76.75	69.0
{C ₂ , C ₅ , C ₈ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	41.5	73.06	64.45
{C ₂ , C ₅ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	46.67	75.12	67.36
{C ₂ , C ₅ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	36.5	74.94	64.45
{C ₂ , C ₅ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	36.83	75.88	65.23
{C ₂ , C ₆ , C ₇ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	45.5	78.31	69.36
{C ₂ , C ₆ , C ₈ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	42.5	76.06	66.91
{C ₂ , C ₆ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	45.83	77.44	68.82
{C ₂ , C ₆ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	38.67	78.38	67.55
{C ₂ , C ₆ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	38.83	79.25	68.23
{C ₂ , C ₇ , C ₈ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	38.5	75.69	65.55
{C ₂ , C ₇ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	42.67	77.38	67.91
{C ₂ , C ₇ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	35.83	78.44	66.82
{C ₂ , C ₇ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	36.5	79.5	67.77
{C ₂ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	47.5	78.06	69.73
{C ₂ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	43.17	80.06	70.0
{C ₂ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	37.83	78.88	67.68
{C ₂ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	46.67	81.5	72.0
{C ₂ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	45.0	81.69	71.68
{C ₂ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	37.17	82.38	70.05
{C ₃ , C ₄ , C ₅ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	52.0	76.06	69.5
{C ₃ , C ₄ , C ₆ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	49.17	77.62	69.86
{C ₃ , C ₄ , C ₇ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	50.83	79.38	71.59
{C ₃ , C ₄ , C ₈ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	43.67	75.56	66.86
{C ₃ , C ₄ , C ₉ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	44.83	76.12	67.59
{C ₃ , C ₄ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	42.17	78.75	68.77

{C ₃ , C ₄ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	48.33	81.88	72.73
{C ₃ , C ₅ , C ₆ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	51.33	77.25	70.18
{C ₃ , C ₅ , C ₇ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	51.0	78.25	70.82
{C ₃ , C ₅ , C ₈ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	44.17	74.56	66.27
{C ₃ , C ₅ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	46.0	75.38	67.36
{C ₃ , C ₅ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	38.67	76.25	66.0
{C ₃ , C ₅ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	41.17	78.0	67.95
{C ₃ , C ₆ , C ₇ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	48.5	79.94	71.36
{C ₃ , C ₆ , C ₈ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	45.5	77.69	68.91
{C ₃ , C ₆ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	45.5	77.81	69.0
{C ₃ , C ₆ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	41.17	79.81	69.27
{C ₃ , C ₆ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	43.5	81.5	71.14
{C ₃ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	40.67	77.0	67.09
{C ₃ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	41.5	77.44	67.64
{C ₃ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	37.5	79.56	68.09
{C ₃ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	40.33	81.44	70.23
{C ₃ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	46.33	78.12	69.45
{C ₃ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	44.83	81.19	71.27
{C ₃ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	41.67	80.81	70.14
{C ₃ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	45.0	81.38	71.45
{C ₃ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	45.5	82.38	72.32
{C ₃ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	40.5	84.12	72.23
{C ₄ , C ₅ , C ₆ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	48.5	77.75	69.77
{C ₄ , C ₅ , C ₇ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	53.0	80.56	73.05
{C ₄ , C ₅ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	43.67	75.94	67.14
{C ₄ , C ₅ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	43.5	76.0	67.14
{C ₄ , C ₅ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	37.0	77.19	66.23
{C ₄ , C ₅ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	40.17	79.19	68.55
{C ₄ , C ₆ , C ₇ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	45.17	80.25	70.68
{C ₄ , C ₆ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	39.67	77.06	66.86
{C ₄ , C ₆ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	37.67	76.44	65.86
{C ₄ , C ₆ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	34.17	78.75	66.59
{C ₄ , C ₆ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	37.17	80.69	68.82
{C ₄ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	39.67	78.19	67.68
{C ₄ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	38.5	77.88	67.14
{C ₄ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	35.33	80.31	68.05
{C ₄ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	38.83	82.44	70.55
{C ₄ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	40.83	77.62	67.59
{C ₄ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	40.17	81.0	69.86
{C ₄ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	37.67	80.88	69.09
{C ₄ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	38.33	80.44	68.95
{C ₄ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	39.5	81.69	70.18
{C ₄ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	35.33	83.75	70.55
{C ₅ , C ₆ , C ₇ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	53.0	82.0	74.09
{C ₅ , C ₆ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	47.83	78.94	70.45
{C ₅ , C ₆ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	46.5	78.56	69.82
{C ₅ , C ₆ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₁ }	38.33	79.12	68.0
{C ₅ , C ₆ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ }	37.67	79.69	68.23
{C ₅ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	45.83	79.31	70.18
{C ₅ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	45.33	79.25	70.0
{C ₅ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₁ }	37.5	79.94	68.36
{C ₅ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ }	37.33	80.69	68.86
{C ₅ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	48.0	79.12	70.64
{C ₅ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	42.67	80.75	70.36
{C ₅ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	36.5	79.25	67.59
{C ₅ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	41.5	80.44	69.82

{C5, C9, C11}	{C1, C2, C3, C4, C6, C7, C8, C10}	39.0	80.31	69.05
{C5, C10, C11}	{C1, C2, C3, C4, C6, C7, C8, C9}	30.17	80.62	66.86
{C6, C7, C8}	{C1, C2, C3, C4, C5, C9, C10, C11}	42.17	80.56	70.09
{C6, C7, C9}	{C1, C2, C3, C4, C5, C8, C10, C11}	39.83	79.81	68.91
{C6, C7, C10}	{C1, C2, C3, C4, C5, C8, C9, C11}	35.0	81.62	68.91
{C6, C7, C11}	{C1, C2, C3, C4, C5, C8, C9, C10}	34.67	82.31	69.32
{C6, C8, C9}	{C1, C2, C3, C4, C5, C7, C10, C11}	46.33	81.12	71.64
{C6, C8, C10}	{C1, C2, C3, C4, C5, C7, C9, C11}	44.0	83.88	73.0
{C6, C8, C11}	{C1, C2, C3, C4, C5, C7, C9, C10}	37.67	82.31	70.14
{C6, C9, C10}	{C1, C2, C3, C4, C5, C7, C8, C11}	41.0	82.88	71.45
{C6, C9, C11}	{C1, C2, C3, C4, C5, C7, C8, C10}	38.33	82.69	70.59
{C6, C10, C11}	{C1, C2, C3, C4, C5, C7, C8, C9}	32.5	84.12	70.05
{C7, C8, C9}	{C1, C2, C3, C4, C5, C6, C10, C11}	40.67	80.12	69.36
{C7, C8, C10}	{C1, C2, C3, C4, C5, C6, C9, C11}	38.67	83.0	70.91
{C7, C8, C11}	{C1, C2, C3, C4, C5, C6, C9, C10}	32.83	81.62	68.32
{C7, C9, C10}	{C1, C2, C3, C4, C5, C6, C8, C11}	36.5	82.31	69.82
{C7, C9, C11}	{C1, C2, C3, C4, C5, C6, C8, C10}	34.33	82.31	69.23
{C7, C10, C11}	{C1, C2, C3, C4, C5, C6, C8, C9}	28.83	83.88	68.86
{C8, C9, C10}	{C1, C2, C3, C4, C5, C6, C7, C11}	53.33	87.5	78.18
{C8, C9, C11}	{C1, C2, C3, C4, C5, C6, C7, C10}	45.17	85.25	74.32
{C8, C10, C11}	{C1, C2, C3, C4, C5, C6, C7, C9}	42.17	87.75	75.32
{C9, C10, C11}	{C1, C2, C3, C4, C5, C6, C7, C8}	43.0	88.19	75.86
{C1, C2, C3, C4}	{C5, C6, C7, C8, C9, C10, C11}	67.75	70.64	69.59
{C1, C2, C3, C5}	{C4, C6, C7, C8, C9, C10, C11}	63.5	66.86	65.64
{C1, C2, C3, C6}	{C4, C5, C7, C8, C9, C10, C11}	62.88	69.5	67.09
{C1, C2, C3, C7}	{C4, C5, C6, C8, C9, C10, C11}	63.0	70.86	68.0
{C1, C2, C3, C8}	{C4, C5, C6, C7, C9, C10, C11}	57.38	66.36	63.09
{C1, C2, C3, C9}	{C4, C5, C6, C7, C8, C10, C11}	61.12	68.64	65.91
{C1, C2, C3, C10}	{C4, C5, C6, C7, C8, C9, C11}	55.88	69.79	64.73
{C1, C2, C3, C11}	{C4, C5, C6, C7, C8, C9, C10}	60.0	73.07	68.32
{C1, C2, C4, C5}	{C3, C6, C7, C8, C9, C10, C11}	62.62	68.14	66.14
{C1, C2, C4, C6}	{C3, C5, C7, C8, C9, C10, C11}	58.0	68.5	64.68
{C1, C2, C4, C7}	{C3, C5, C6, C8, C9, C10, C11}	61.75	71.93	68.23
{C1, C2, C4, C8}	{C3, C5, C6, C7, C9, C10, C11}	54.25	66.36	61.95
{C1, C2, C4, C9}	{C3, C5, C6, C7, C8, C10, C11}	56.5	67.79	63.68
{C1, C2, C4, C10}	{C3, C5, C6, C7, C8, C9, C11}	51.88	69.29	62.95
{C1, C2, C4, C11}	{C3, C5, C6, C7, C8, C9, C10}	56.5	72.86	66.91
{C1, C2, C5, C6}	{C3, C4, C7, C8, C9, C10, C11}	59.5	68.0	64.91
{C1, C2, C5, C7}	{C3, C4, C6, C8, C9, C10, C11}	61.75	70.57	67.36
{C1, C2, C5, C8}	{C3, C4, C6, C7, C9, C10, C11}	54.5	65.14	61.27
{C1, C2, C5, C9}	{C3, C4, C6, C7, C8, C10, C11}	57.25	66.86	63.36
{C1, C2, C5, C10}	{C3, C4, C6, C7, C8, C9, C11}	49.12	66.36	60.09
{C1, C2, C5, C11}	{C3, C4, C6, C7, C8, C9, C10}	51.0	68.36	62.05
{C1, C2, C6, C7}	{C3, C4, C5, C8, C9, C10, C11}	57.38	71.07	66.09
{C1, C2, C6, C8}	{C3, C4, C5, C7, C9, C10, C11}	53.0	67.29	62.09
{C1, C2, C6, C9}	{C3, C4, C5, C7, C8, C10, C11}	54.38	68.21	63.18
{C1, C2, C6, C10}	{C3, C4, C5, C7, C8, C9, C11}	48.5	69.0	61.55
{C1, C2, C6, C11}	{C3, C4, C5, C7, C8, C9, C10}	50.25	70.93	63.41
{C1, C2, C7, C8}	{C3, C4, C5, C6, C9, C10, C11}	51.88	67.93	62.09
{C1, C2, C7, C9}	{C3, C4, C5, C6, C8, C10, C11}	53.88	69.21	63.64
{C1, C2, C7, C10}	{C3, C4, C5, C6, C8, C9, C11}	48.25	70.14	62.18
{C1, C2, C7, C11}	{C3, C4, C5, C6, C8, C9, C10}	50.38	72.29	64.32
{C1, C2, C8, C9}	{C3, C4, C5, C6, C7, C10, C11}	55.38	68.79	63.91
{C1, C2, C8, C10}	{C3, C4, C5, C6, C7, C9, C11}	51.62	70.79	63.82
{C1, C2, C8, C11}	{C3, C4, C5, C6, C7, C9, C10}	49.25	70.36	62.68
{C1, C2, C9, C10}	{C3, C4, C5, C6, C7, C8, C11}	53.12	71.79	65.0

{C ₁ , C ₂ , C ₉ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	53.5	72.93	65.86
{C ₁ , C ₂ , C ₁₀ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	47.12	73.43	63.86
{C ₁ , C ₃ , C ₄ , C ₅ }	{C ₂ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	65.5	70.36	68.59
{C ₁ , C ₃ , C ₄ , C ₆ }	{C ₂ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	61.12	70.86	67.32
{C ₁ , C ₃ , C ₄ , C ₇ }	{C ₂ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	64.25	73.93	70.41
{C ₁ , C ₃ , C ₄ , C ₈ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	56.75	68.36	64.14
{C ₁ , C ₃ , C ₄ , C ₉ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	56.5	68.36	64.05
{C ₁ , C ₃ , C ₄ , C ₁₀ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	54.0	71.07	64.86
{C ₁ , C ₃ , C ₄ , C ₁₁ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	60.25	75.57	70.0
{C ₁ , C ₃ , C ₅ , C ₆ }	{C ₂ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	62.12	70.07	67.18
{C ₁ , C ₃ , C ₅ , C ₇ }	{C ₂ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	63.75	72.29	69.18
{C ₁ , C ₃ , C ₅ , C ₈ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	56.5	66.86	63.09
{C ₁ , C ₃ , C ₅ , C ₉ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	56.75	67.14	63.36
{C ₁ , C ₃ , C ₅ , C ₁₀ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	50.75	67.86	61.64
{C ₁ , C ₃ , C ₅ , C ₁₁ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	54.25	70.79	64.77
{C ₁ , C ₃ , C ₆ , C ₇ }	{C ₂ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	59.62	72.93	68.09
{C ₁ , C ₃ , C ₆ , C ₈ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	55.25	69.14	64.09
{C ₁ , C ₃ , C ₆ , C ₉ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	54.12	68.64	63.36
{C ₁ , C ₃ , C ₆ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	50.38	70.64	63.27
{C ₁ , C ₃ , C ₆ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	53.75	73.5	66.32
{C ₁ , C ₃ , C ₇ , C ₈ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	53.5	69.43	63.64
{C ₁ , C ₃ , C ₇ , C ₉ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	53.0	69.29	63.36
{C ₁ , C ₃ , C ₇ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	49.5	71.43	63.45
{C ₁ , C ₃ , C ₇ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	53.25	74.5	66.77
{C ₁ , C ₃ , C ₈ , C ₉ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	54.5	68.86	63.64
{C ₁ , C ₃ , C ₈ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	52.88	72.07	65.09
{C ₁ , C ₃ , C ₈ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	52.12	72.57	65.14
{C ₁ , C ₃ , C ₉ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	51.88	71.64	64.45
{C ₁ , C ₃ , C ₉ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	53.88	73.71	66.5
{C ₁ , C ₃ , C ₁₀ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	49.62	75.43	66.05
{C ₁ , C ₄ , C ₅ , C ₆ }	{C ₂ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	63.62	72.71	69.41
{C ₁ , C ₄ , C ₅ , C ₇ }	{C ₂ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	68.88	77.0	74.05
{C ₁ , C ₄ , C ₅ , C ₈ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	59.75	70.5	66.59
{C ₁ , C ₄ , C ₅ , C ₉ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	58.5	69.93	65.77
{C ₁ , C ₄ , C ₅ , C ₁₀ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	53.12	71.0	64.5
{C ₁ , C ₄ , C ₅ , C ₁₁ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	57.12	74.21	68.0
{C ₁ , C ₄ , C ₆ , C ₇ }	{C ₂ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	60.75	75.36	70.05
{C ₁ , C ₄ , C ₆ , C ₈ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	54.5	70.5	64.68
{C ₁ , C ₄ , C ₆ , C ₉ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	51.88	69.14	62.86
{C ₁ , C ₄ , C ₆ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	48.75	71.5	63.23
{C ₁ , C ₄ , C ₆ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	52.62	74.64	66.64
{C ₁ , C ₄ , C ₇ , C ₈ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	56.38	72.86	66.86
{C ₁ , C ₄ , C ₇ , C ₉ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	54.38	71.86	65.5
{C ₁ , C ₄ , C ₇ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	51.5	74.36	66.05
{C ₁ , C ₄ , C ₇ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	55.75	77.71	69.73
{C ₁ , C ₄ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	54.0	70.36	64.41
{C ₁ , C ₄ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	53.0	73.93	66.32
{C ₁ , C ₄ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	52.75	74.71	66.73
{C ₁ , C ₄ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	50.5	72.64	64.59
{C ₁ , C ₄ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	53.0	75.0	67.0
{C ₁ , C ₄ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	49.38	77.07	67.0
{C ₁ , C ₅ , C ₆ , C ₇ }	{C ₂ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	66.0	77.0	73.0
{C ₁ , C ₅ , C ₆ , C ₈ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	60.0	72.29	67.82
{C ₁ , C ₅ , C ₆ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	57.88	71.21	66.36
{C ₁ , C ₅ , C ₆ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₁ }	51.25	71.57	64.18
{C ₁ , C ₅ , C ₆ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ }	52.38	73.14	65.59

{C ₁ , C ₅ , C ₇ , C ₈ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	60.38	73.79	68.91
{C ₁ , C ₅ , C ₇ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	58.88	73.07	67.91
{C ₁ , C ₅ , C ₇ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₁ }	52.5	73.57	65.91
{C ₁ , C ₅ , C ₇ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ }	54.0	75.36	67.59
{C ₁ , C ₅ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	58.75	71.71	67.0
{C ₁ , C ₅ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	54.25	73.29	66.36
{C ₁ , C ₅ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	51.25	72.5	64.77
{C ₁ , C ₅ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	52.25	72.29	65.0
{C ₁ , C ₅ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ }	52.0	73.07	65.41
{C ₁ , C ₅ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ }	44.88	73.14	62.86
{C ₁ , C ₆ , C ₇ , C ₈ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	55.38	73.93	67.18
{C ₁ , C ₆ , C ₇ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	52.5	72.43	65.18
{C ₁ , C ₆ , C ₇ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₁ }	48.38	74.21	64.82
{C ₁ , C ₆ , C ₇ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ }	49.75	75.93	66.41
{C ₁ , C ₆ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	55.25	72.71	66.36
{C ₁ , C ₆ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₁ }	53.0	75.57	67.36
{C ₁ , C ₆ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ }	49.88	74.71	65.68
{C ₁ , C ₆ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₁ }	49.62	73.79	65.0
{C ₁ , C ₆ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ }	49.25	74.5	65.32
{C ₁ , C ₆ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ }	44.38	75.86	64.41
{C ₁ , C ₇ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	52.88	72.64	65.45
{C ₁ , C ₇ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₁ }	50.88	75.64	66.64
{C ₁ , C ₇ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ }	48.12	75.0	65.23
{C ₁ , C ₇ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₁ }	48.12	74.21	64.73
{C ₁ , C ₇ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ }	48.12	75.14	65.32
{C ₁ , C ₇ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ }	43.5	76.64	64.59
{C ₁ , C ₈ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₁ }	58.62	78.93	71.55
{C ₁ , C ₈ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ }	54.12	77.29	68.86
{C ₁ , C ₈ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ }	51.38	79.86	69.5
{C ₁ , C ₉ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ }	50.88	79.71	69.23
{C ₂ , C ₃ , C ₄ , C ₅ }	{C ₁ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	63.12	68.57	66.59
{C ₂ , C ₃ , C ₄ , C ₆ }	{C ₁ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	61.88	70.86	67.59
{C ₂ , C ₃ , C ₄ , C ₇ }	{C ₁ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	62.88	72.71	69.14
{C ₂ , C ₃ , C ₄ , C ₈ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	55.75	67.36	63.14
{C ₂ , C ₃ , C ₄ , C ₉ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	59.62	69.71	66.05
{C ₂ , C ₃ , C ₄ , C ₁₀ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	56.38	72.0	66.32
{C ₂ , C ₃ , C ₄ , C ₁₁ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	61.0	75.57	70.27
{C ₂ , C ₃ , C ₅ , C ₆ }	{C ₁ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	61.75	69.43	66.64
{C ₂ , C ₃ , C ₅ , C ₇ }	{C ₁ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	61.25	70.43	67.09
{C ₂ , C ₃ , C ₅ , C ₈ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	54.38	65.21	61.27
{C ₂ , C ₃ , C ₅ , C ₉ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	58.75	67.86	64.55
{C ₂ , C ₃ , C ₅ , C ₁₀ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	52.0	68.14	62.27
{C ₂ , C ₃ , C ₅ , C ₁₁ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	53.88	70.14	64.23
{C ₂ , C ₃ , C ₆ , C ₇ }	{C ₁ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	60.25	72.86	68.27
{C ₂ , C ₃ , C ₆ , C ₈ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	56.25	69.29	64.55
{C ₂ , C ₃ , C ₆ , C ₉ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	59.25	71.14	66.82
{C ₂ , C ₃ , C ₆ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	54.75	72.71	66.18
{C ₂ , C ₃ , C ₆ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	56.5	74.64	68.05
{C ₂ , C ₃ , C ₇ , C ₈ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	52.38	68.36	62.55
{C ₂ , C ₃ , C ₇ , C ₉ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	56.0	70.57	65.27
{C ₂ , C ₃ , C ₇ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	51.75	72.29	64.82
{C ₂ , C ₃ , C ₇ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	53.88	74.43	66.95
{C ₂ , C ₃ , C ₈ , C ₉ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	57.88	70.36	65.82
{C ₂ , C ₃ , C ₈ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	55.5	73.14	66.73
{C ₂ , C ₃ , C ₈ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	53.12	72.71	65.59
{C ₂ , C ₃ , C ₉ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	58.62	75.07	69.09

{C ₂ , C ₃ , C ₉ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	59.0	76.21	69.95
{C ₂ , C ₃ , C ₁₀ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	54.0	77.5	68.95
{C ₂ , C ₄ , C ₅ , C ₆ }	{C ₁ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	56.25	68.07	63.77
{C ₂ , C ₄ , C ₅ , C ₇ }	{C ₁ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	59.38	71.14	66.86
{C ₂ , C ₄ , C ₅ , C ₈ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	50.62	64.86	59.68
{C ₂ , C ₄ , C ₅ , C ₉ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	53.5	66.64	61.86
{C ₂ , C ₄ , C ₅ , C ₁₀ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	47.38	67.29	60.05
{C ₂ , C ₄ , C ₅ , C ₁₁ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	49.75	69.57	62.36
{C ₂ , C ₄ , C ₆ , C ₇ }	{C ₁ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	54.38	71.29	65.14
{C ₂ , C ₄ , C ₆ , C ₈ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	48.5	66.64	60.05
{C ₂ , C ₄ , C ₆ , C ₉ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	50.0	67.64	61.23
{C ₂ , C ₄ , C ₆ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	46.12	69.57	61.05
{C ₂ , C ₄ , C ₆ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	48.38	71.79	63.27
{C ₂ , C ₄ , C ₇ , C ₈ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	48.25	67.79	60.68
{C ₂ , C ₄ , C ₇ , C ₉ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	50.38	69.14	62.32
{C ₂ , C ₄ , C ₇ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	46.75	71.21	62.32
{C ₂ , C ₄ , C ₇ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	49.38	73.64	64.82
{C ₂ , C ₄ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	50.38	67.86	61.5
{C ₂ , C ₄ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	48.62	71.0	62.86
{C ₂ , C ₄ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	46.75	70.86	62.09
{C ₂ , C ₄ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	50.25	72.07	64.14
{C ₂ , C ₄ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	51.12	73.5	65.36
{C ₂ , C ₄ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	46.75	75.14	64.82
{C ₂ , C ₅ , C ₆ , C ₇ }	{C ₁ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	58.5	72.29	67.27
{C ₂ , C ₅ , C ₆ , C ₈ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	52.88	67.79	62.36
{C ₂ , C ₅ , C ₆ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	54.88	69.07	63.91
{C ₂ , C ₅ , C ₆ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₁ }	47.5	69.0	61.18
{C ₂ , C ₅ , C ₆ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ }	47.0	69.64	61.41
{C ₂ , C ₅ , C ₇ , C ₈ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	51.12	68.07	61.91
{C ₂ , C ₅ , C ₇ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	53.75	69.71	63.91
{C ₂ , C ₅ , C ₇ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₁ }	46.62	69.79	61.36
{C ₂ , C ₅ , C ₇ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ }	46.5	70.64	61.86
{C ₂ , C ₅ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	54.0	68.57	63.27
{C ₂ , C ₅ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	48.75	69.71	62.09
{C ₂ , C ₅ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	44.12	68.0	59.32
{C ₂ , C ₅ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	50.88	71.07	63.73
{C ₂ , C ₅ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ }	49.0	70.93	62.95
{C ₂ , C ₅ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ }	41.12	70.57	59.86
{C ₂ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	49.25	70.0	62.45
{C ₂ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	50.5	70.86	63.45
{C ₂ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₁ }	45.62	72.21	62.55
{C ₂ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ }	45.38	73.0	62.95
{C ₂ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	53.62	71.36	64.91
{C ₂ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₁ }	50.62	73.79	65.36
{C ₂ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ }	45.88	72.0	62.5
{C ₂ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₁ }	51.38	74.36	66.0
{C ₂ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ }	49.38	74.14	65.14
{C ₂ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ }	43.75	75.07	63.68
{C ₂ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	49.12	70.07	62.45
{C ₂ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₁ }	46.38	72.64	63.09
{C ₂ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ }	42.0	71.07	60.5
{C ₂ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₁ }	47.75	73.57	64.18
{C ₂ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ }	46.12	73.57	63.59
{C ₂ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ }	40.75	74.64	62.32
{C ₂ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₁ }	58.62	78.5	71.27
{C ₂ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ }	52.5	75.93	67.41

{C ₂ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ }	49.0	78.07	67.5
{C ₂ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ }	52.62	80.29	70.23
{C ₃ , C ₄ , C ₅ , C ₆ }	{C ₁ , C ₂ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	58.62	70.0	65.86
{C ₃ , C ₄ , C ₅ , C ₇ }	{C ₁ , C ₂ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	61.12	72.71	68.5
{C ₃ , C ₄ , C ₅ , C ₈ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	52.38	66.43	61.32
{C ₃ , C ₄ , C ₅ , C ₉ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	52.75	66.79	61.68
{C ₃ , C ₄ , C ₅ , C ₁₀ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	48.75	68.64	61.41
{C ₃ , C ₄ , C ₅ , C ₁₁ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	52.75	71.86	64.91
{C ₃ , C ₄ , C ₆ , C ₇ }	{C ₁ , C ₂ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	56.38	73.0	66.95
{C ₃ , C ₄ , C ₆ , C ₈ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	50.5	68.36	61.86
{C ₃ , C ₄ , C ₆ , C ₉ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	49.5	67.93	61.23
{C ₃ , C ₄ , C ₆ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	47.75	71.07	62.59
{C ₃ , C ₄ , C ₆ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	51.62	74.21	66.0
{C ₃ , C ₄ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	49.62	69.14	62.05
{C ₃ , C ₄ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	49.25	69.07	61.86
{C ₃ , C ₄ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	47.75	72.36	63.41
{C ₃ , C ₄ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	52.0	75.71	67.09
{C ₃ , C ₄ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	49.25	67.79	61.05
{C ₃ , C ₄ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	49.62	72.14	63.95
{C ₃ , C ₄ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	49.38	72.93	64.36
{C ₃ , C ₄ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	48.75	71.79	63.41
{C ₃ , C ₄ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	51.25	74.14	65.82
{C ₃ , C ₄ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	49.0	77.0	66.82
{C ₃ , C ₅ , C ₆ , C ₇ }	{C ₁ , C ₂ , C ₄ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	60.0	73.71	68.73
{C ₃ , C ₅ , C ₆ , C ₈ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	54.38	69.21	63.82
{C ₃ , C ₅ , C ₆ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	53.88	69.07	63.55
{C ₃ , C ₅ , C ₆ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₁ }	48.62	70.21	62.36
{C ₃ , C ₅ , C ₆ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ }	49.75	71.79	63.77
{C ₃ , C ₅ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	52.0	69.14	62.91
{C ₃ , C ₅ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	52.12	69.36	63.09
{C ₃ , C ₅ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₁ }	47.12	70.64	62.09
{C ₃ , C ₅ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ }	48.62	72.43	63.77
{C ₃ , C ₅ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	52.38	68.21	62.45
{C ₃ , C ₅ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	49.25	70.57	62.82
{C ₃ , C ₅ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	46.25	69.79	61.23
{C ₃ , C ₅ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	48.88	70.5	62.64
{C ₃ , C ₅ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ }	48.62	71.29	63.05
{C ₃ , C ₅ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ }	42.88	72.14	61.5
{C ₃ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	50.38	71.21	63.64
{C ₃ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	49.12	70.64	62.82
{C ₃ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₁ }	46.38	73.21	63.45
{C ₃ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ }	47.75	74.93	65.05
{C ₃ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	52.25	71.14	64.27
{C ₃ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₁ }	51.38	74.79	66.27
{C ₃ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ }	48.25	73.93	64.59
{C ₃ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₁ }	49.62	73.93	65.09
{C ₃ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ }	49.25	74.64	65.41
{C ₃ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ }	45.75	76.79	65.5
{C ₃ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	47.12	69.5	61.36
{C ₃ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₁ }	46.5	73.29	63.55
{C ₃ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ }	43.75	72.64	62.14
{C ₃ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₁ }	45.38	72.79	62.82
{C ₃ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ }	45.38	73.71	63.41
{C ₃ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ }	42.12	76.0	63.68
{C ₃ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₁ }	56.25	77.71	69.91
{C ₃ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ }	51.75	76.07	67.23

{C ₃ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ }	50.38	79.43	68.86
{C ₃ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ }	51.5	80.21	69.77
{C ₄ , C ₅ , C ₆ , C ₇ }	{C ₁ , C ₂ , C ₃ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	60.5	75.79	70.23
{C ₄ , C ₅ , C ₆ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	53.0	70.21	63.95
{C ₄ , C ₅ , C ₆ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	51.0	69.21	62.59
{C ₄ , C ₅ , C ₆ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₁ }	46.38	70.71	61.86
{C ₄ , C ₅ , C ₆ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	48.0	72.57	63.64
{C ₄ , C ₅ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	54.25	72.21	65.68
{C ₄ , C ₅ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	52.88	71.57	64.77
{C ₄ , C ₅ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₁ }	48.5	73.21	64.23
{C ₄ , C ₅ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₀ }	50.5	75.29	66.27
{C ₄ , C ₅ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	51.25	69.36	62.77
{C ₄ , C ₅ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₁ }	48.75	72.07	63.59
{C ₄ , C ₅ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₀ }	46.25	71.57	62.36
{C ₄ , C ₅ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₁ }	46.88	71.14	62.32
{C ₄ , C ₅ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₀ }	47.12	72.21	63.09
{C ₄ , C ₅ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ }	42.0	73.43	62.0
{C ₄ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	48.62	72.0	63.5
{C ₄ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	45.88	70.57	61.59
{C ₄ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₁ }	43.75	73.5	62.68
{C ₄ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₀ }	45.62	75.5	64.64
{C ₄ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	47.12	70.0	61.68
{C ₄ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₁ }	46.88	74.0	64.14
{C ₄ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₀ }	44.25	73.43	62.82
{C ₄ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₁ }	43.62	72.29	61.86
{C ₄ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₀ }	43.75	73.29	62.55
{C ₄ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ }	40.88	75.79	63.09
{C ₄ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	45.62	70.43	61.41
{C ₄ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₁ }	45.62	74.57	64.05
{C ₄ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₀ }	43.38	74.21	63.0
{C ₄ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₁ }	43.0	73.21	62.23
{C ₄ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ }	43.5	74.43	63.18
{C ₄ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ }	40.88	77.07	63.91
{C ₄ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₁ }	52.0	77.07	67.95
{C ₄ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ }	48.0	75.71	65.64
{C ₄ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ }	47.25	79.43	67.73
{C ₄ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ }	46.88	79.36	67.55
{C ₅ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₉ , C ₁₀ , C ₁₁ }	56.75	75.29	68.55
{C ₅ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₈ , C ₁₀ , C ₁₁ }	54.5	74.14	67.0
{C ₅ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₁ }	48.88	75.07	65.55
{C ₅ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ }	48.0	75.5	65.5
{C ₅ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₁₀ , C ₁₁ }	56.0	73.71	67.27
{C ₅ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₁ }	52.25	75.71	67.18
{C ₅ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ }	46.88	73.57	63.86
{C ₅ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₁ }	49.5	74.29	65.27
{C ₅ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ }	46.88	73.71	63.95
{C ₅ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ }	40.5	74.21	61.95
{C ₅ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₁₀ , C ₁₁ }	53.0	73.29	65.91
{C ₅ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₁ }	49.5	75.43	66.0
{C ₅ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ }	44.5	73.5	62.95
{C ₅ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₁ }	47.38	74.36	64.55
{C ₅ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ }	45.12	74.0	63.5
{C ₅ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ }	39.0	74.64	61.68
{C ₅ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₁ }	56.62	78.36	70.45
{C ₅ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ }	49.88	75.43	66.14
{C ₅ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ }	45.62	77.14	65.68

{C5, C9, C10, C11}	{C1, C2, C3, C4, C6, C7, C8}	45.75	77.36	65.86
{C6, C7, C8, C9}	{C1, C2, C3, C4, C5, C10, C11}	49.12	74.07	65.0
{C6, C7, C8, C10}	{C1, C2, C3, C4, C5, C9, C11}	47.88	77.5	66.73
{C6, C7, C8, C11}	{C1, C2, C3, C4, C5, C9, C10}	42.75	75.5	63.59
{C6, C7, C9, C10}	{C1, C2, C3, C4, C5, C8, C11}	44.38	75.64	64.27
{C6, C7, C9, C11}	{C1, C2, C3, C4, C5, C8, C10}	42.0	75.21	63.14
{C6, C7, C10, C11}	{C1, C2, C3, C4, C5, C8, C9}	38.12	77.14	62.95
{C6, C8, C9, C10}	{C1, C2, C3, C4, C5, C7, C11}	56.5	81.29	72.27
{C6, C8, C9, C11}	{C1, C2, C3, C4, C5, C7, C10}	49.62	78.29	67.86
{C6, C8, C10, C11}	{C1, C2, C3, C4, C5, C7, C9}	47.62	81.29	69.05
{C6, C9, C10, C11}	{C1, C2, C3, C4, C5, C7, C8}	46.38	80.71	68.23
{C7, C8, C9, C10}	{C1, C2, C3, C4, C5, C6, C11}	51.0	79.43	69.09
{C7, C8, C9, C11}	{C1, C2, C3, C4, C5, C6, C10}	44.5	76.64	64.95
{C7, C8, C10, C11}	{C1, C2, C3, C4, C5, C6, C9}	42.75	79.79	66.32
{C7, C9, C10, C11}	{C1, C2, C3, C4, C5, C6, C8}	42.12	79.57	65.95
{C8, C9, C10, C11}	{C1, C2, C3, C4, C5, C6, C7}	57.5	87.07	76.32
{C1, C2, C3, C4, C5}	{C6, C7, C8, C9, C10, C11}	73.0	61.75	66.86
{C1, C2, C3, C4, C6}	{C5, C7, C8, C9, C10, C11}	70.2	62.92	66.23
{C1, C2, C3, C4, C7}	{C5, C6, C8, C9, C10, C11}	72.5	66.33	69.14
{C1, C2, C3, C4, C8}	{C5, C6, C7, C9, C10, C11}	65.1	58.67	61.59
{C1, C2, C3, C4, C9}	{C5, C6, C7, C8, C10, C11}	67.3	60.67	63.68
{C1, C2, C3, C4, C10}	{C5, C6, C7, C8, C9, C11}	64.3	63.0	63.59
{C1, C2, C3, C4, C11}	{C5, C6, C7, C8, C9, C10}	69.3	68.25	68.73
{C1, C2, C3, C5, C6}	{C4, C7, C8, C9, C10, C11}	69.6	60.83	64.82
{C1, C2, C3, C5, C7}	{C4, C6, C8, C9, C10, C11}	70.7	63.25	66.64
{C1, C2, C3, C5, C8}	{C4, C6, C7, C9, C10, C11}	63.5	55.75	59.27
{C1, C2, C3, C5, C9}	{C4, C6, C7, C8, C10, C11}	66.1	58.08	61.73
{C1, C2, C3, C5, C10}	{C4, C6, C7, C8, C9, C11}	60.3	58.08	59.09
{C1, C2, C3, C5, C11}	{C4, C6, C7, C8, C9, C10}	63.1	61.5	62.23
{C1, C2, C3, C6, C7}	{C4, C5, C8, C9, C10, C11}	68.1	64.58	66.18
{C1, C2, C3, C6, C8}	{C4, C5, C7, C9, C10, C11}	63.2	59.0	60.91
{C1, C2, C3, C6, C9}	{C4, C5, C7, C8, C10, C11}	64.7	60.42	62.36
{C1, C2, C3, C6, C10}	{C4, C5, C7, C8, C9, C11}	60.7	61.92	61.36
{C1, C2, C3, C6, C11}	{C4, C5, C7, C8, C9, C10}	63.4	65.25	64.41
{C1, C2, C3, C7, C8}	{C4, C5, C6, C9, C10, C11}	61.6	59.17	60.27
{C1, C2, C3, C7, C9}	{C4, C5, C6, C8, C10, C11}	63.6	61.0	62.18
{C1, C2, C3, C7, C10}	{C4, C5, C6, C8, C9, C11}	59.8	62.67	61.36
{C1, C2, C3, C7, C11}	{C4, C5, C6, C8, C9, C10}	62.8	66.25	64.68
{C1, C2, C3, C8, C9}	{C4, C5, C6, C7, C10, C11}	63.4	59.33	61.18
{C1, C2, C3, C8, C10}	{C4, C5, C6, C7, C9, C11}	61.1	62.25	61.73
{C1, C2, C3, C8, C11}	{C4, C5, C6, C7, C9, C10}	60.5	62.83	61.77
{C1, C2, C3, C9, C10}	{C4, C5, C6, C7, C8, C11}	62.7	63.75	63.27
{C1, C2, C3, C9, C11}	{C4, C5, C6, C7, C8, C10}	64.3	66.17	65.32
{C1, C2, C3, C10, C11}	{C4, C5, C6, C7, C8, C9}	59.9	67.33	63.95
{C1, C2, C4, C5, C6}	{C3, C7, C8, C9, C10, C11}	68.1	61.67	64.59
{C1, C2, C4, C5, C7}	{C3, C6, C8, C9, C10, C11}	72.1	66.5	69.05
{C1, C2, C4, C5, C8}	{C3, C6, C7, C9, C10, C11}	63.4	57.75	60.32
{C1, C2, C4, C5, C9}	{C3, C6, C7, C8, C10, C11}	64.8	59.08	61.68
{C1, C2, C4, C5, C10}	{C3, C6, C7, C8, C9, C11}	59.5	59.5	59.5
{C1, C2, C4, C5, C11}	{C3, C6, C7, C8, C9, C10}	62.7	63.25	63.0
{C1, C2, C4, C6, C7}	{C3, C5, C8, C9, C10, C11}	66.3	65.17	65.68
{C1, C2, C4, C6, C8}	{C3, C5, C7, C9, C10, C11}	59.9	58.33	59.05
{C1, C2, C4, C6, C9}	{C3, C5, C7, C8, C10, C11}	60.2	58.75	59.41
{C1, C2, C4, C6, C10}	{C3, C5, C7, C8, C9, C11}	56.7	60.67	58.86
{C1, C2, C4, C6, C11}	{C3, C5, C7, C8, C9, C10}	59.8	64.33	62.27
{C1, C2, C4, C7, C8}	{C3, C5, C6, C9, C10, C11}	61.2	60.92	61.05

{C ₁ , C ₂ , C ₄ , C ₇ , C ₉ }	{C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	62.0	61.75	61.86
{C ₁ , C ₂ , C ₄ , C ₇ , C ₁₀ }	{C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	58.7	63.83	61.5
{C ₁ , C ₂ , C ₄ , C ₇ , C ₁₁ }	{C ₃ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	62.1	67.75	65.18
{C ₁ , C ₂ , C ₄ , C ₈ , C ₉ }	{C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	60.3	58.83	59.5
{C ₁ , C ₂ , C ₄ , C ₈ , C ₁₀ }	{C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	58.5	62.17	60.5
{C ₁ , C ₂ , C ₄ , C ₈ , C ₁₁ }	{C ₃ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	58.3	63.08	60.91
{C ₁ , C ₂ , C ₄ , C ₉ , C ₁₀ }	{C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	58.9	62.67	60.95
{C ₁ , C ₂ , C ₄ , C ₉ , C ₁₁ }	{C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	60.9	65.42	63.36
{C ₁ , C ₂ , C ₄ , C ₁₀ , C ₁₁ }	{C ₃ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	57.0	67.0	62.45
{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ }	{C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	69.1	65.92	67.36
{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ }	{C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	62.9	59.25	60.91
{C ₁ , C ₂ , C ₅ , C ₆ , C ₉ }	{C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	63.6	60.0	61.64
{C ₁ , C ₂ , C ₅ , C ₆ , C ₁₀ }	{C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₁ }	57.3	59.58	58.55
{C ₁ , C ₂ , C ₅ , C ₆ , C ₁₁ }	{C ₃ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ }	58.2	61.42	59.95
{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ }	{C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	63.0	60.83	61.82
{C ₁ , C ₂ , C ₅ , C ₇ , C ₉ }	{C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	64.2	62.0	63.0
{C ₁ , C ₂ , C ₅ , C ₇ , C ₁₀ }	{C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₁ }	58.1	61.75	60.09
{C ₁ , C ₂ , C ₅ , C ₇ , C ₁₁ }	{C ₃ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ }	59.3	63.83	61.77
{C ₁ , C ₂ , C ₅ , C ₈ , C ₉ }	{C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	62.7	59.25	60.82
{C ₁ , C ₂ , C ₅ , C ₈ , C ₁₀ }	{C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	58.1	60.25	59.27
{C ₁ , C ₂ , C ₅ , C ₈ , C ₁₁ }	{C ₃ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	55.7	59.33	57.68
{C ₁ , C ₂ , C ₅ , C ₉ , C ₁₀ }	{C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	58.9	61.08	60.09
{C ₁ , C ₂ , C ₅ , C ₉ , C ₁₁ }	{C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ }	58.7	62.0	60.5
{C ₁ , C ₂ , C ₅ , C ₁₀ , C ₁₁ }	{C ₃ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ }	52.0	61.25	57.05
{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ }	{C ₃ , C ₄ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	59.7	61.58	60.73
{C ₁ , C ₂ , C ₆ , C ₇ , C ₉ }	{C ₃ , C ₄ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	59.8	61.83	60.91
{C ₁ , C ₂ , C ₆ , C ₇ , C ₁₀ }	{C ₃ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₁ }	55.5	63.08	59.64
{C ₁ , C ₂ , C ₆ , C ₇ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ }	56.6	65.08	61.23
{C ₁ , C ₂ , C ₆ , C ₈ , C ₉ }	{C ₃ , C ₄ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	60.6	61.0	60.82
{C ₁ , C ₂ , C ₆ , C ₈ , C ₁₀ }	{C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₁ }	57.8	63.5	60.91
{C ₁ , C ₂ , C ₆ , C ₈ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ }	55.3	62.5	59.23
{C ₁ , C ₂ , C ₆ , C ₉ , C ₁₀ }	{C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₁ }	57.5	63.42	60.73
{C ₁ , C ₂ , C ₆ , C ₉ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ }	57.2	64.25	61.05
{C ₁ , C ₂ , C ₆ , C ₁₀ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ }	52.3	65.0	59.23
{C ₁ , C ₂ , C ₇ , C ₈ , C ₉ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	58.5	60.75	59.73
{C ₁ , C ₂ , C ₇ , C ₈ , C ₁₀ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₁ }	55.9	63.42	60.0
{C ₁ , C ₂ , C ₇ , C ₈ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ }	53.7	62.67	58.59
{C ₁ , C ₂ , C ₇ , C ₉ , C ₁₀ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₁ }	56.1	63.75	60.27
{C ₁ , C ₂ , C ₇ , C ₉ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ }	56.1	64.83	60.86
{C ₁ , C ₂ , C ₇ , C ₁₀ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ }	51.4	65.75	59.23
{C ₁ , C ₂ , C ₈ , C ₉ , C ₁₀ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₁ }	63.1	68.08	65.82
{C ₁ , C ₂ , C ₈ , C ₉ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ }	59.5	66.17	63.14
{C ₁ , C ₂ , C ₈ , C ₁₀ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ }	56.3	68.33	62.86
{C ₁ , C ₂ , C ₉ , C ₁₀ , C ₁₁ }	{C ₃ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ }	58.3	70.17	64.77
{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ }	{C ₂ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	70.0	63.92	66.68
{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ }	{C ₂ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	73.5	68.33	70.68
{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ }	{C ₂ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	64.8	59.58	61.95
{C ₁ , C ₃ , C ₄ , C ₅ , C ₉ }	{C ₂ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	64.2	59.25	61.5
{C ₁ , C ₃ , C ₄ , C ₅ , C ₁₀ }	{C ₂ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	60.6	61.08	60.86
{C ₁ , C ₃ , C ₄ , C ₅ , C ₁₁ }	{C ₂ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	65.1	65.92	65.55
{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ }	{C ₂ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	67.9	67.17	67.5
{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ }	{C ₂ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	61.5	60.33	60.86
{C ₁ , C ₃ , C ₄ , C ₆ , C ₉ }	{C ₂ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	59.8	59.08	59.41
{C ₁ , C ₃ , C ₄ , C ₆ , C ₁₀ }	{C ₂ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	58.0	62.42	60.41
{C ₁ , C ₃ , C ₄ , C ₆ , C ₁₁ }	{C ₂ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	62.4	67.17	65.0
{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ }	{C ₂ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	62.3	62.5	62.41

{C ₁ , C ₃ , C ₄ , C ₇ , C ₉ }	{C ₂ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	61.1	61.67	61.41
{C ₁ , C ₃ , C ₄ , C ₇ , C ₁₀ }	{C ₂ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	59.5	65.17	62.59
{C ₁ , C ₃ , C ₄ , C ₇ , C ₁₁ }	{C ₂ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	64.2	70.17	67.45
{C ₁ , C ₃ , C ₄ , C ₈ , C ₉ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	59.4	58.75	59.05
{C ₁ , C ₃ , C ₄ , C ₈ , C ₁₀ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	59.3	63.5	61.59
{C ₁ , C ₃ , C ₄ , C ₈ , C ₁₁ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	60.4	65.5	63.18
{C ₁ , C ₃ , C ₄ , C ₉ , C ₁₀ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	57.7	62.33	60.23
{C ₁ , C ₃ , C ₄ , C ₉ , C ₁₁ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	61.0	66.17	63.82
{C ₁ , C ₃ , C ₄ , C ₁₀ , C ₁₁ }	{C ₂ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	58.8	69.17	64.45
{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ }	{C ₂ , C ₄ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	70.3	67.58	68.82
{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ }	{C ₂ , C ₄ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	64.1	60.92	62.36
{C ₁ , C ₃ , C ₅ , C ₆ , C ₉ }	{C ₂ , C ₄ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	62.8	60.0	61.27
{C ₁ , C ₃ , C ₅ , C ₆ , C ₁₀ }	{C ₂ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₁ }	58.2	61.0	59.73
{C ₁ , C ₃ , C ₅ , C ₆ , C ₁₁ }	{C ₂ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ }	60.4	63.92	62.32
{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ }	{C ₂ , C ₄ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	63.7	62.08	62.82
{C ₁ , C ₃ , C ₅ , C ₇ , C ₉ }	{C ₂ , C ₄ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	62.9	61.58	62.18
{C ₁ , C ₃ , C ₅ , C ₇ , C ₁₀ }	{C ₂ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₁ }	58.5	62.75	60.82
{C ₁ , C ₃ , C ₅ , C ₇ , C ₁₁ }	{C ₂ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ }	61.0	65.92	63.68
{C ₁ , C ₃ , C ₅ , C ₈ , C ₉ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	61.4	58.83	60.0
{C ₁ , C ₃ , C ₅ , C ₈ , C ₁₀ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	58.5	61.25	60.0
{C ₁ , C ₃ , C ₅ , C ₈ , C ₁₁ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	57.4	61.42	59.59
{C ₁ , C ₃ , C ₅ , C ₉ , C ₁₀ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	57.3	60.42	59.0
{C ₁ , C ₃ , C ₅ , C ₉ , C ₁₁ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ }	58.4	62.42	60.59
{C ₁ , C ₃ , C ₅ , C ₁₀ , C ₁₁ }	{C ₂ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ }	53.4	63.08	58.68
{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ }	{C ₂ , C ₄ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	60.6	63.0	61.91
{C ₁ , C ₃ , C ₆ , C ₇ , C ₉ }	{C ₂ , C ₄ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	58.7	61.58	60.27
{C ₁ , C ₃ , C ₆ , C ₇ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₁ }	56.1	64.25	60.55
{C ₁ , C ₃ , C ₆ , C ₇ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ }	58.5	67.33	63.32
{C ₁ , C ₃ , C ₆ , C ₈ , C ₉ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	59.5	60.75	60.18
{C ₁ , C ₃ , C ₆ , C ₈ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₁ }	58.4	64.67	61.82
{C ₁ , C ₃ , C ₆ , C ₈ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ }	57.2	64.75	61.32
{C ₁ , C ₃ , C ₆ , C ₉ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₁ }	56.1	62.92	59.82
{C ₁ , C ₃ , C ₆ , C ₉ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ }	57.1	64.83	61.32
{C ₁ , C ₃ , C ₆ , C ₁₀ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ }	53.9	67.0	61.05
{C ₁ , C ₃ , C ₇ , C ₈ , C ₉ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	56.9	60.08	58.64
{C ₁ , C ₃ , C ₇ , C ₈ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₁ }	56.0	64.17	60.45
{C ₁ , C ₃ , C ₇ , C ₈ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ }	55.1	64.5	60.23
{C ₁ , C ₃ , C ₇ , C ₉ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₁ }	54.2	62.83	58.91
{C ₁ , C ₃ , C ₇ , C ₉ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ }	55.5	65.0	60.68
{C ₁ , C ₃ , C ₇ , C ₁₀ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ }	52.5	67.33	60.59
{C ₁ , C ₃ , C ₈ , C ₉ , C ₁₀ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₁ }	61.2	67.17	64.45
{C ₁ , C ₃ , C ₈ , C ₉ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ }	58.9	66.33	62.95
{C ₁ , C ₃ , C ₈ , C ₁₀ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ }	57.4	69.92	64.23
{C ₁ , C ₃ , C ₉ , C ₁₀ , C ₁₁ }	{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ }	57.4	70.08	64.32
{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ }	{C ₂ , C ₃ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	73.6	72.42	72.95
{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ }	{C ₂ , C ₃ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	65.9	64.5	65.14
{C ₁ , C ₄ , C ₅ , C ₆ , C ₉ }	{C ₂ , C ₃ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	63.4	62.58	62.95
{C ₁ , C ₄ , C ₅ , C ₆ , C ₁₀ }	{C ₂ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₁ }	59.3	64.0	61.86
{C ₁ , C ₄ , C ₅ , C ₆ , C ₁₁ }	{C ₂ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₀ }	61.9	67.25	64.82
{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ }	{C ₂ , C ₃ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	68.4	68.08	68.23
{C ₁ , C ₄ , C ₅ , C ₇ , C ₉ }	{C ₂ , C ₃ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	66.4	66.58	66.5
{C ₁ , C ₄ , C ₅ , C ₇ , C ₁₀ }	{C ₂ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₁ }	62.5	68.17	65.59
{C ₁ , C ₄ , C ₅ , C ₇ , C ₁₁ }	{C ₂ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₀ }	65.4	71.67	68.82
{C ₁ , C ₄ , C ₅ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	63.4	62.58	62.95
{C ₁ , C ₄ , C ₅ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₁ }	61.0	65.42	63.41
{C ₁ , C ₄ , C ₅ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₀ }	60.3	65.92	63.36

{C ₁ , C ₄ , C ₅ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₁ }	58.6	63.58	61.32
{C ₁ , C ₄ , C ₅ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₀ }	60.1	65.92	63.27
{C ₁ , C ₄ , C ₅ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ }	55.6	67.0	61.82
{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ }	{C ₂ , C ₃ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	62.1	66.33	64.41
{C ₁ , C ₄ , C ₆ , C ₇ , C ₉ }	{C ₂ , C ₃ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	59.0	63.92	61.68
{C ₁ , C ₄ , C ₆ , C ₇ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₁ }	56.9	67.0	62.41
{C ₁ , C ₄ , C ₆ , C ₇ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₀ }	59.7	70.42	65.55
{C ₁ , C ₄ , C ₆ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	58.3	61.83	60.23
{C ₁ , C ₄ , C ₆ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₁ }	57.7	66.17	62.32
{C ₁ , C ₄ , C ₆ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₀ }	56.9	66.58	62.18
{C ₁ , C ₄ , C ₆ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₁ }	54.2	63.42	59.23
{C ₁ , C ₄ , C ₆ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₀ }	55.6	65.67	61.09
{C ₁ , C ₄ , C ₆ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ }	52.9	68.25	61.27
{C ₁ , C ₄ , C ₇ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	58.6	63.58	61.32
{C ₁ , C ₄ , C ₇ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₁ }	58.2	68.08	63.59
{C ₁ , C ₄ , C ₇ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₀ }	57.7	68.75	63.73
{C ₁ , C ₄ , C ₇ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₁ }	55.2	65.75	60.95
{C ₁ , C ₄ , C ₇ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ }	56.9	68.25	63.09
{C ₁ , C ₄ , C ₇ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ }	54.4	71.0	63.45
{C ₁ , C ₄ , C ₈ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₁ }	60.7	68.83	65.14
{C ₁ , C ₄ , C ₈ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ }	58.8	68.33	64.0
{C ₁ , C ₄ , C ₈ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ }	57.8	72.33	65.73
{C ₁ , C ₄ , C ₉ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ }	56.6	71.5	64.73
{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ }	{C ₂ , C ₃ , C ₄ , C ₉ , C ₁₀ , C ₁₁ }	68.1	69.75	69.0
{C ₁ , C ₅ , C ₆ , C ₇ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₈ , C ₁₀ , C ₁₁ }	65.4	67.67	66.64
{C ₁ , C ₅ , C ₆ , C ₇ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₁ }	60.5	68.42	64.82
{C ₁ , C ₅ , C ₆ , C ₇ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ }	61.1	70.0	65.95
{C ₁ , C ₅ , C ₆ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₁₀ , C ₁₁ }	64.9	65.75	65.36
{C ₁ , C ₅ , C ₆ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₁ }	61.5	67.75	64.91
{C ₁ , C ₅ , C ₆ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ }	58.5	66.33	62.77
{C ₁ , C ₅ , C ₆ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₁ }	58.4	65.33	62.18
{C ₁ , C ₅ , C ₆ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ }	57.6	65.75	62.05
{C ₁ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ }	52.1	66.0	59.68
{C ₁ , C ₅ , C ₇ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₁₀ , C ₁₁ }	64.0	66.5	65.36
{C ₁ , C ₅ , C ₇ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₁ }	60.8	68.67	65.09
{C ₁ , C ₅ , C ₇ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ }	58.1	67.5	63.23
{C ₁ , C ₅ , C ₇ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₁ }	58.2	66.67	62.82
{C ₁ , C ₅ , C ₇ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ }	57.7	67.33	62.95
{C ₁ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ }	52.4	67.75	60.77
{C ₁ , C ₅ , C ₈ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₁ }	63.9	69.92	67.18
{C ₁ , C ₅ , C ₈ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ }	59.8	67.58	64.05
{C ₁ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ }	56.0	69.25	63.23
{C ₁ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ }	55.2	68.75	62.59
{C ₁ , C ₆ , C ₇ , C ₈ , C ₉ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₁₀ , C ₁₁ }	59.1	65.92	62.82
{C ₁ , C ₆ , C ₇ , C ₈ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₉ , C ₁₁ }	57.7	69.58	64.18
{C ₁ , C ₆ , C ₇ , C ₈ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₉ , C ₁₀ }	54.9	68.33	62.23
{C ₁ , C ₆ , C ₇ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₈ , C ₁₁ }	54.0	66.67	60.91
{C ₁ , C ₆ , C ₇ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₈ , C ₁₀ }	53.4	67.25	60.95
{C ₁ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₈ , C ₉ }	49.9	69.17	60.41
{C ₁ , C ₆ , C ₈ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₁₁ }	62.0	71.83	67.36
{C ₁ , C ₆ , C ₈ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₁₀ }	57.8	69.42	64.14
{C ₁ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ }	55.8	72.58	64.95
{C ₁ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ }	53.9	71.17	63.32
{C ₁ , C ₇ , C ₈ , C ₉ , C ₁₀ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₁₁ }	59.1	70.92	65.55
{C ₁ , C ₇ , C ₈ , C ₉ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₁₀ }	55.2	68.75	62.59
{C ₁ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ }	53.4	72.08	63.59

{C ₁ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ }	52.0	71.08	62.41
{C ₁ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ }	62.6	78.42	71.23
{C ₂ , C ₃ , C ₄ , C ₅ , C ₆ }	{C ₁ , C ₇ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	69.5	63.0	65.95
{C ₂ , C ₃ , C ₄ , C ₅ , C ₇ }	{C ₁ , C ₆ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	71.3	66.0	68.41
{C ₂ , C ₃ , C ₄ , C ₅ , C ₈ }	{C ₁ , C ₆ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	62.9	57.5	59.95
{C ₂ , C ₃ , C ₄ , C ₅ , C ₉ }	{C ₁ , C ₆ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	65.6	59.92	62.5
{C ₂ , C ₃ , C ₄ , C ₅ , C ₁₀ }	{C ₁ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₁ }	61.4	61.25	61.32
{C ₂ , C ₃ , C ₄ , C ₅ , C ₁₁ }	{C ₁ , C ₆ , C ₇ , C ₈ , C ₉ , C ₁₀ }	64.6	65.0	64.82
{C ₂ , C ₃ , C ₄ , C ₆ , C ₇ }	{C ₁ , C ₅ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	68.2	66.92	67.5
{C ₂ , C ₃ , C ₄ , C ₆ , C ₈ }	{C ₁ , C ₅ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	62.1	60.33	61.14
{C ₂ , C ₃ , C ₄ , C ₆ , C ₉ }	{C ₁ , C ₅ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	63.7	61.83	62.68
{C ₂ , C ₃ , C ₄ , C ₆ , C ₁₀ }	{C ₁ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₁ }	61.3	64.67	63.14
{C ₂ , C ₃ , C ₄ , C ₆ , C ₁₁ }	{C ₁ , C ₅ , C ₇ , C ₈ , C ₉ , C ₁₀ }	64.4	68.33	66.55
{C ₂ , C ₃ , C ₄ , C ₇ , C ₈ }	{C ₁ , C ₅ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	61.2	61.08	61.14
{C ₂ , C ₃ , C ₄ , C ₇ , C ₉ }	{C ₁ , C ₅ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	63.3	63.0	63.14
{C ₂ , C ₃ , C ₄ , C ₇ , C ₁₀ }	{C ₁ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₁ }	61.1	66.0	63.77
{C ₂ , C ₃ , C ₄ , C ₇ , C ₁₁ }	{C ₁ , C ₅ , C ₆ , C ₈ , C ₉ , C ₁₀ }	64.5	69.92	67.45
{C ₂ , C ₃ , C ₄ , C ₈ , C ₉ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	61.9	60.33	61.05
{C ₂ , C ₃ , C ₄ , C ₈ , C ₁₀ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₁ }	61.2	64.58	63.05
{C ₂ , C ₃ , C ₄ , C ₈ , C ₁₁ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₉ , C ₁₀ }	61.0	65.5	63.45
{C ₂ , C ₃ , C ₄ , C ₉ , C ₁₀ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₁ }	62.9	66.17	64.68
{C ₂ , C ₃ , C ₄ , C ₉ , C ₁₁ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ , C ₁₀ }	64.9	68.92	67.09
{C ₂ , C ₃ , C ₄ , C ₁₀ , C ₁₁ }	{C ₁ , C ₅ , C ₆ , C ₇ , C ₈ , C ₉ }	62.1	71.42	67.18
{C ₂ , C ₃ , C ₅ , C ₆ , C ₇ }	{C ₁ , C ₄ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	69.7	66.58	68.0
{C ₂ , C ₃ , C ₅ , C ₆ , C ₈ }	{C ₁ , C ₄ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	63.8	60.17	61.82
{C ₂ , C ₃ , C ₅ , C ₆ , C ₉ }	{C ₁ , C ₄ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	65.8	62.0	63.73
{C ₂ , C ₃ , C ₅ , C ₆ , C ₁₀ }	{C ₁ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₁ }	60.6	62.5	61.64
{C ₂ , C ₃ , C ₅ , C ₆ , C ₁₁ }	{C ₁ , C ₄ , C ₇ , C ₈ , C ₉ , C ₁₀ }	61.5	64.33	63.05
{C ₂ , C ₃ , C ₅ , C ₇ , C ₈ }	{C ₁ , C ₄ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	61.7	59.92	60.73
{C ₂ , C ₃ , C ₅ , C ₇ , C ₉ }	{C ₁ , C ₄ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	64.2	62.17	63.09
{C ₂ , C ₃ , C ₅ , C ₇ , C ₁₀ }	{C ₁ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₁ }	59.2	62.83	61.18
{C ₂ , C ₃ , C ₅ , C ₇ , C ₁₁ }	{C ₁ , C ₄ , C ₆ , C ₈ , C ₉ , C ₁₀ }	60.4	64.92	62.86
{C ₂ , C ₃ , C ₅ , C ₈ , C ₉ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	63.0	59.67	61.18
{C ₂ , C ₃ , C ₅ , C ₈ , C ₁₀ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	59.5	61.58	60.64
{C ₂ , C ₃ , C ₅ , C ₈ , C ₁₁ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	57.1	60.67	59.05
{C ₂ , C ₃ , C ₅ , C ₉ , C ₁₀ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	61.6	63.5	62.64
{C ₂ , C ₃ , C ₅ , C ₉ , C ₁₁ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ }	61.4	64.42	63.05
{C ₂ , C ₃ , C ₅ , C ₁₀ , C ₁₁ }	{C ₁ , C ₄ , C ₆ , C ₇ , C ₈ , C ₉ }	55.8	64.58	60.59
{C ₂ , C ₃ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₄ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	61.1	62.92	62.09
{C ₂ , C ₃ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₄ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	62.5	64.25	63.45
{C ₂ , C ₃ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₁ }	59.3	66.42	63.18
{C ₂ , C ₃ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ }	60.4	68.42	64.77
{C ₂ , C ₃ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	63.6	63.67	63.64
{C ₂ , C ₃ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₁ }	61.9	67.08	64.73
{C ₂ , C ₃ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ }	59.4	66.08	63.05
{C ₂ , C ₃ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₁ }	62.9	68.08	65.73
{C ₂ , C ₃ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ }	62.6	68.92	66.05
{C ₂ , C ₃ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₇ , C ₈ , C ₉ }	58.8	70.58	65.23
{C ₂ , C ₃ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	59.3	61.58	60.55
{C ₂ , C ₃ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₁ }	57.8	65.17	61.82
{C ₂ , C ₃ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ }	55.6	64.42	60.41
{C ₂ , C ₃ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₁ }	59.3	66.58	63.27
{C ₂ , C ₃ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ }	59.3	67.67	63.86
{C ₂ , C ₃ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₈ , C ₉ }	55.7	69.5	63.23
{C ₂ , C ₃ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₁ }	66.6	71.17	69.09
{C ₂ , C ₃ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ }	63.0	69.25	66.41

{C ₂ , C ₃ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₉ }	60.9	72.33	67.14
{C ₂ , C ₃ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₄ , C ₅ , C ₆ , C ₇ , C ₈ }	64.2	75.25	70.23
{C ₂ , C ₄ , C ₅ , C ₆ , C ₇ }	{C ₁ , C ₃ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	67.4	66.75	67.05
{C ₂ , C ₄ , C ₅ , C ₆ , C ₈ }	{C ₁ , C ₃ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	60.0	59.08	59.5
{C ₂ , C ₄ , C ₅ , C ₆ , C ₉ }	{C ₁ , C ₃ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	60.8	59.92	60.32
{C ₂ , C ₄ , C ₅ , C ₆ , C ₁₀ }	{C ₁ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₁ }	56.1	60.83	58.68
{C ₂ , C ₄ , C ₅ , C ₆ , C ₁₁ }	{C ₁ , C ₃ , C ₇ , C ₈ , C ₉ , C ₁₀ }	57.4	63.0	60.45
{C ₂ , C ₄ , C ₅ , C ₇ , C ₈ }	{C ₁ , C ₃ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	60.8	61.25	61.05
{C ₂ , C ₄ , C ₅ , C ₇ , C ₉ }	{C ₁ , C ₃ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	62.1	62.5	62.32
{C ₂ , C ₄ , C ₅ , C ₇ , C ₁₀ }	{C ₁ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₁ }	57.6	63.58	60.86
{C ₂ , C ₄ , C ₅ , C ₇ , C ₁₁ }	{C ₁ , C ₃ , C ₆ , C ₈ , C ₉ , C ₁₀ }	59.2	66.0	62.91
{C ₂ , C ₄ , C ₅ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	59.4	58.75	59.05
{C ₂ , C ₄ , C ₅ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₁ }	56.4	61.08	58.95
{C ₂ , C ₄ , C ₅ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₉ , C ₁₀ }	54.4	60.5	57.73
{C ₂ , C ₄ , C ₅ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₁ }	57.3	62.0	59.86
{C ₂ , C ₄ , C ₅ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ , C ₁₀ }	57.5	63.25	60.64
{C ₂ , C ₄ , C ₅ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₆ , C ₇ , C ₈ , C ₉ }	52.4	63.83	58.64
{C ₂ , C ₄ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₃ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	57.0	61.58	59.5
{C ₂ , C ₄ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₃ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	57.2	61.92	59.77
{C ₂ , C ₄ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₁ }	54.5	64.5	59.95
{C ₂ , C ₄ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₈ , C ₉ , C ₁₀ }	56.0	66.83	61.91
{C ₂ , C ₄ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	56.8	60.08	58.59
{C ₂ , C ₄ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₁ }	55.6	63.92	60.14
{C ₂ , C ₄ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₉ , C ₁₀ }	53.5	63.25	58.82
{C ₂ , C ₄ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₁ }	55.4	63.92	60.05
{C ₂ , C ₄ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ , C ₁₀ }	55.5	65.08	60.73
{C ₂ , C ₄ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₇ , C ₈ , C ₉ }	52.2	67.17	60.36
{C ₂ , C ₄ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	55.4	60.42	58.14
{C ₂ , C ₄ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₁ }	54.4	64.42	59.86
{C ₂ , C ₄ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₉ , C ₁₀ }	52.6	64.0	58.82
{C ₂ , C ₄ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₁ }	54.7	64.83	60.23
{C ₂ , C ₄ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ }	55.1	66.25	61.18
{C ₂ , C ₄ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₈ , C ₉ }	52.0	68.5	61.0
{C ₂ , C ₄ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₁ }	60.5	68.17	64.68
{C ₂ , C ₄ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ }	57.3	66.58	62.36
{C ₂ , C ₄ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₉ }	55.7	70.08	63.55
{C ₂ , C ₄ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₅ , C ₆ , C ₇ , C ₈ }	57.8	72.0	65.55
{C ₂ , C ₅ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₃ , C ₄ , C ₉ , C ₁₀ , C ₁₁ }	62.1	64.25	63.27
{C ₂ , C ₅ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₈ , C ₁₀ , C ₁₁ }	62.7	64.92	63.91
{C ₂ , C ₅ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₁ }	57.2	65.17	61.55
{C ₂ , C ₅ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ }	56.5	65.67	61.5
{C ₂ , C ₅ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₁₀ , C ₁₁ }	62.5	63.25	62.91
{C ₂ , C ₅ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₁ }	58.5	64.75	61.91
{C ₂ , C ₅ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ }	54.2	62.25	58.59
{C ₂ , C ₅ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₁ }	58.7	65.08	62.18
{C ₂ , C ₅ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ }	56.6	64.42	60.86
{C ₂ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₇ , C ₈ , C ₉ }	50.5	64.17	57.95
{C ₂ , C ₅ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₁₀ , C ₁₁ }	59.9	62.58	61.36
{C ₂ , C ₅ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₁ }	56.1	64.25	60.55
{C ₂ , C ₅ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ }	52.1	62.0	57.5
{C ₂ , C ₅ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₁ }	56.8	65.0	61.27
{C ₂ , C ₅ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ }	55.0	64.58	60.23
{C ₂ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₈ , C ₉ }	49.1	64.5	57.5
{C ₂ , C ₅ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₁ }	62.8	68.5	65.91
{C ₂ , C ₅ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ }	57.4	65.08	61.59
{C ₂ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₉ }	53.0	66.25	60.23

{C ₂ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₆ , C ₇ , C ₈ }	55.5	68.5	62.59
{C ₂ , C ₆ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₁₀ , C ₁₁ }	57.5	64.08	61.09
{C ₂ , C ₆ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₉ , C ₁₁ }	55.5	67.25	61.91
{C ₂ , C ₆ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₉ , C ₁₀ }	51.4	64.92	58.77
{C ₂ , C ₆ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ , C ₁₁ }	55.1	67.08	61.64
{C ₂ , C ₆ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ , C ₁₀ }	53.2	66.58	60.5
{C ₂ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₈ , C ₉ }	49.1	68.0	59.41
{C ₂ , C ₆ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₁₁ }	63.4	72.5	68.36
{C ₂ , C ₆ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₁₀ }	57.9	69.0	63.95
{C ₂ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₉ }	55.3	71.67	64.23
{C ₂ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₇ , C ₈ }	56.7	73.0	65.59
{C ₂ , C ₇ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₁₁ }	58.8	70.17	65.0
{C ₂ , C ₇ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₁₀ }	53.6	66.92	60.86
{C ₂ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₉ }	51.2	69.75	61.32
{C ₂ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₈ }	53.1	71.5	63.14
{C ₂ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₃ , C ₄ , C ₅ , C ₆ , C ₇ }	64.0	79.08	72.23
{C ₃ , C ₄ , C ₅ , C ₆ , C ₇ }	{C ₁ , C ₂ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	68.4	68.25	68.32
{C ₃ , C ₄ , C ₅ , C ₆ , C ₈ }	{C ₁ , C ₂ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	61.0	60.58	60.77
{C ₃ , C ₄ , C ₅ , C ₆ , C ₉ }	{C ₁ , C ₂ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	59.8	59.75	59.77
{C ₃ , C ₄ , C ₅ , C ₆ , C ₁₀ }	{C ₁ , C ₂ , C ₇ , C ₈ , C ₉ , C ₁₁ }	56.8	62.08	59.68
{C ₃ , C ₄ , C ₅ , C ₆ , C ₁₁ }	{C ₁ , C ₂ , C ₇ , C ₈ , C ₉ , C ₁₀ }	59.4	65.33	62.64
{C ₃ , C ₄ , C ₅ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	61.3	62.33	61.86
{C ₃ , C ₄ , C ₅ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	60.6	61.92	61.32
{C ₃ , C ₄ , C ₅ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₆ , C ₈ , C ₉ , C ₁₁ }	57.8	64.42	61.41
{C ₃ , C ₄ , C ₅ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₆ , C ₈ , C ₉ , C ₁₀ }	60.7	67.92	64.64
{C ₃ , C ₄ , C ₅ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	57.9	58.17	58.05
{C ₃ , C ₄ , C ₅ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₉ , C ₁₁ }	56.6	61.92	59.5
{C ₃ , C ₄ , C ₅ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₉ , C ₁₀ }	55.9	62.42	59.45
{C ₃ , C ₄ , C ₅ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ , C ₁₁ }	55.5	61.17	58.59
{C ₃ , C ₄ , C ₅ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ , C ₁₀ }	57.0	63.5	60.55
{C ₃ , C ₄ , C ₅ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₆ , C ₇ , C ₈ , C ₉ }	53.6	65.5	60.09
{C ₃ , C ₄ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	57.7	62.83	60.5
{C ₃ , C ₄ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	55.9	61.5	58.95
{C ₃ , C ₄ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₈ , C ₉ , C ₁₁ }	54.9	65.5	60.68
{C ₃ , C ₄ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₈ , C ₉ , C ₁₀ }	57.7	68.92	63.82
{C ₃ , C ₄ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	55.5	59.67	57.77
{C ₃ , C ₄ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₉ , C ₁₁ }	56.0	64.92	60.86
{C ₃ , C ₄ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₉ , C ₁₀ }	55.2	65.33	60.73
{C ₃ , C ₄ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ , C ₁₁ }	53.8	63.25	58.95
{C ₃ , C ₄ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ , C ₁₀ }	55.2	65.5	60.82
{C ₃ , C ₄ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₇ , C ₈ , C ₉ }	53.6	69.0	62.0
{C ₃ , C ₄ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	53.6	59.58	56.86
{C ₃ , C ₄ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₉ , C ₁₁ }	54.3	65.0	60.14
{C ₃ , C ₄ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₉ , C ₁₀ }	53.8	65.67	60.27
{C ₃ , C ₄ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ , C ₁₁ }	52.6	63.75	58.68
{C ₃ , C ₄ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ , C ₁₀ }	54.3	66.25	60.82
{C ₃ , C ₄ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₈ , C ₉ }	52.9	69.92	62.18
{C ₃ , C ₄ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₁₁ }	58.4	67.08	63.14
{C ₃ , C ₄ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₁₀ }	56.5	66.58	62.0
{C ₃ , C ₄ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₉ }	56.6	71.5	64.73
{C ₃ , C ₄ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₅ , C ₆ , C ₇ , C ₈ }	56.7	71.75	64.91
{C ₃ , C ₅ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₄ , C ₉ , C ₁₀ , C ₁₁ }	62.4	65.17	63.91
{C ₃ , C ₅ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₈ , C ₁₀ , C ₁₁ }	61.0	64.17	62.73
{C ₃ , C ₅ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₈ , C ₉ , C ₁₁ }	57.2	65.83	61.91
{C ₃ , C ₅ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₈ , C ₉ , C ₁₀ }	57.8	67.42	63.05
{C ₃ , C ₅ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₁₀ , C ₁₁ }	60.8	62.5	61.73

{C ₃ , C ₅ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₉ , C ₁₁ }	58.5	65.42	62.27
{C ₃ , C ₅ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₉ , C ₁₀ }	55.5	64.0	60.14
{C ₃ , C ₅ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₈ , C ₁₁ }	56.7	64.08	60.73
{C ₃ , C ₅ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₈ , C ₁₀ }	55.9	64.5	60.59
{C ₃ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₇ , C ₈ , C ₉ }	51.5	65.67	59.23
{C ₃ , C ₅ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₁₀ , C ₁₁ }	57.7	61.42	59.73
{C ₃ , C ₅ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₉ , C ₁₁ }	55.6	64.5	60.45
{C ₃ , C ₅ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₉ , C ₁₀ }	52.9	63.33	58.59
{C ₃ , C ₅ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₈ , C ₁₁ }	54.3	63.58	59.36
{C ₃ , C ₅ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₈ , C ₁₀ }	53.8	64.25	59.5
{C ₃ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₈ , C ₉ }	49.6	65.58	58.32
{C ₃ , C ₅ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₁₁ }	60.3	67.08	64.0
{C ₃ , C ₅ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₁₀ }	56.2	64.75	60.86
{C ₃ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₉ }	53.5	67.33	61.05
{C ₃ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₆ , C ₇ , C ₈ }	54.0	67.92	61.59
{C ₃ , C ₆ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₁₀ , C ₁₁ }	55.5	63.08	59.64
{C ₃ , C ₆ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₉ , C ₁₁ }	55.2	67.67	62.0
{C ₃ , C ₆ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₉ , C ₁₀ }	52.4	66.42	60.05
{C ₃ , C ₆ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₈ , C ₁₁ }	52.8	65.83	59.91
{C ₃ , C ₆ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₈ , C ₁₀ }	52.2	66.42	59.95
{C ₃ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₈ , C ₉ }	49.8	69.25	60.41
{C ₃ , C ₆ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₁₁ }	61.1	71.25	66.64
{C ₃ , C ₆ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₁₀ }	56.9	68.83	63.41
{C ₃ , C ₆ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₉ }	56.0	72.92	65.23
{C ₃ , C ₆ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₇ , C ₈ }	55.4	72.58	64.77
{C ₃ , C ₇ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₁₁ }	56.0	68.5	62.82
{C ₃ , C ₇ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₁₀ }	52.1	66.33	59.86
{C ₃ , C ₇ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₉ }	51.4	70.58	61.86
{C ₃ , C ₇ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₈ }	51.3	70.67	61.86
{C ₃ , C ₈ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₄ , C ₅ , C ₆ , C ₇ }	62.2	78.25	70.95
{C ₄ , C ₅ , C ₆ , C ₇ , C ₈ }	{C ₁ , C ₂ , C ₃ , C ₉ , C ₁₀ , C ₁₁ }	63.4	68.08	65.95
{C ₄ , C ₅ , C ₆ , C ₇ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₈ , C ₁₀ , C ₁₁ }	60.8	66.08	63.68
{C ₄ , C ₅ , C ₆ , C ₇ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₈ , C ₉ , C ₁₁ }	57.5	68.17	63.32
{C ₄ , C ₅ , C ₆ , C ₇ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₈ , C ₉ , C ₁₀ }	58.5	70.08	64.82
{C ₄ , C ₅ , C ₆ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₁₀ , C ₁₁ }	59.1	63.17	61.32
{C ₄ , C ₅ , C ₆ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₉ , C ₁₁ }	57.3	66.5	62.32
{C ₄ , C ₅ , C ₆ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₉ , C ₁₀ }	54.7	65.42	60.55
{C ₄ , C ₅ , C ₆ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₈ , C ₁₁ }	54.3	64.17	59.68
{C ₄ , C ₅ , C ₆ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₈ , C ₁₀ }	53.9	64.92	59.91
{C ₄ , C ₅ , C ₆ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₇ , C ₈ , C ₉ }	50.0	66.5	59.0
{C ₄ , C ₅ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₁₀ , C ₁₁ }	58.9	64.5	61.95
{C ₄ , C ₅ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₉ , C ₁₁ }	57.3	68.0	63.14
{C ₄ , C ₅ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₉ , C ₁₀ }	55.0	67.17	61.64
{C ₄ , C ₅ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₈ , C ₁₁ }	54.8	66.08	60.95
{C ₄ , C ₅ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₈ , C ₁₀ }	54.7	67.08	61.45
{C ₄ , C ₅ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₈ , C ₉ }	51.0	68.83	60.73
{C ₄ , C ₅ , C ₈ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₁₁ }	59.3	68.33	64.23
{C ₄ , C ₅ , C ₈ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₁₀ }	55.6	66.33	61.45
{C ₄ , C ₅ , C ₈ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₉ }	53.4	69.33	62.09
{C ₄ , C ₅ , C ₉ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₆ , C ₇ , C ₈ }	52.7	68.92	61.55
{C ₄ , C ₆ , C ₇ , C ₈ , C ₉ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₁₀ , C ₁₁ }	53.5	63.5	58.95
{C ₄ , C ₆ , C ₇ , C ₈ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₉ , C ₁₁ }	53.7	68.5	61.77
{C ₄ , C ₆ , C ₇ , C ₈ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₉ , C ₁₀ }	51.3	67.58	60.18
{C ₄ , C ₆ , C ₇ , C ₉ , C ₁₀ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₈ , C ₁₁ }	50.1	65.67	58.59
{C ₄ , C ₆ , C ₇ , C ₉ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₈ , C ₁₀ }	49.9	66.58	59.0
{C ₄ , C ₆ , C ₇ , C ₁₀ , C ₁₁ }	{C ₁ , C ₂ , C ₃ , C ₅ , C ₈ , C ₉ }	48.0	69.83	59.91

$\{C_4, C_6, C_8, C_9, C_{10}\}$	$\{C_1, C_2, C_3, C_5, C_7, C_{11}\}$	56.9	69.83	63.95
$\{C_4, C_6, C_8, C_9, C_{11}\}$	$\{C_1, C_2, C_3, C_5, C_7, C_{10}\}$	53.1	67.75	61.09
$\{C_4, C_6, C_8, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_5, C_7, C_9\}$	52.7	72.25	63.36
$\{C_4, C_6, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_5, C_7, C_8\}$	50.9	70.92	61.82
$\{C_4, C_7, C_8, C_9, C_{10}\}$	$\{C_1, C_2, C_3, C_5, C_6, C_{11}\}$	54.7	69.5	62.77
$\{C_4, C_7, C_8, C_9, C_{11}\}$	$\{C_1, C_2, C_3, C_5, C_6, C_{10}\}$	51.2	67.67	60.18
$\{C_4, C_7, C_8, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_5, C_6, C_9\}$	51.0	72.33	62.64
$\{C_4, C_7, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_5, C_6, C_8\}$	49.7	71.42	61.55
$\{C_4, C_8, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_5, C_6, C_7\}$	59.1	77.75	69.27
$\{C_5, C_6, C_7, C_8, C_9\}$	$\{C_1, C_2, C_3, C_4, C_{10}, C_{11}\}$	62.2	69.17	66.0
$\{C_5, C_6, C_7, C_8, C_{10}\}$	$\{C_1, C_2, C_3, C_4, C_9, C_{11}\}$	59.6	71.83	66.27
$\{C_5, C_6, C_7, C_8, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_9, C_{10}\}$	55.0	69.08	62.68
$\{C_5, C_6, C_7, C_9, C_{10}\}$	$\{C_1, C_2, C_3, C_4, C_8, C_{11}\}$	56.4	69.33	63.45
$\{C_5, C_6, C_7, C_9, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_8, C_{10}\}$	54.0	68.42	61.86
$\{C_5, C_6, C_7, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_8, C_9\}$	49.3	69.33	60.23
$\{C_5, C_6, C_8, C_9, C_{10}\}$	$\{C_1, C_2, C_3, C_4, C_7, C_{11}\}$	63.4	73.67	69.0
$\{C_5, C_6, C_8, C_9, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_7, C_{10}\}$	57.4	69.75	64.14
$\{C_5, C_6, C_8, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_7, C_9\}$	54.2	71.92	63.86
$\{C_5, C_6, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_7, C_8\}$	52.8	70.92	62.68
$\{C_5, C_7, C_8, C_9, C_{10}\}$	$\{C_1, C_2, C_3, C_4, C_6, C_{11}\}$	60.0	72.33	66.73
$\{C_5, C_7, C_8, C_9, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_6, C_{10}\}$	54.3	68.67	62.14
$\{C_5, C_7, C_8, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_6, C_9\}$	51.3	71.0	62.05
$\{C_5, C_7, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_6, C_8\}$	50.4	70.42	61.32
$\{C_5, C_8, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_6, C_7\}$	60.0	76.92	69.23
$\{C_6, C_7, C_8, C_9, C_{10}\}$	$\{C_1, C_2, C_3, C_4, C_5, C_{11}\}$	57.8	74.0	66.64
$\{C_6, C_7, C_8, C_9, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_5, C_{10}\}$	52.0	70.25	61.95
$\{C_6, C_7, C_8, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_5, C_9\}$	50.8	74.08	63.5
$\{C_6, C_7, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_5, C_8\}$	48.8	72.58	61.77
$\{C_6, C_8, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_5, C_7\}$	60.7	81.0	71.77
$\{C_7, C_8, C_9, C_{10}, C_{11}\}$	$\{C_1, C_2, C_3, C_4, C_5, C_6\}$	55.6	78.25	67.95