Fundusze Europejskie dla Rozwoju Społecznego

Rzeczpospolita Polska

Dofinansowane przez Unię Europejską

Ćwiczenie nr 6
Obliczenia statystyczne w Excelu



POLITECHNIKA BYDGOSKA
im. Jana i Jędrzeja Śniadeckich

POLITECHNIKA BYDGOSKA
Wydział Technologii i Inżynierii Chemicznej

POLITECHNIKA BYDGOSKA
Wydział Medyczny

PRACOWNIA KOMPUTEROWA

Wstęp

Statystyka odgrywa kluczową rolę w medycynie, umożliwiając lekarzom oraz badaczom wyciąganie wniosków na podstawie zebranych danych. Współczesna praktyka medyczna oraz badania kliniczne opierają się na analizie wyników dużej liczby pacjentów, a umiejętność poprawnej interpretacji tych danych jest niezbędna dla podejmowania właściwych decyzji klinicznych. Program Microsoft Excel, ze swoimi narzędziami do analizy danych, jest często wykorzystywany w medycynie do przeprowadzania podstawowych analiz statystycznych.

Przypomnienie podstawowych miar:

Moda (w Excel nazwa WYST.NAJCZĘŚCIEJ.WART [MODE.SNGL] oraz Tryb w Analizie Danych) jest to wartość pojawiająca się w zbiorze danych najczęściej.

Mediana: jeśli liczba danych jest nieparzysta, mediana to środkowa wartość zbioru. Jeśli liczba danych jest parzysta, mediana to średnia arytmetyczna dwóch środkowych wartości.

Kwartyle są statystycznymi miarami pozycyjnymi, które dzielą uporządkowany zbiór danych na cztery równe części, co pozwala lepiej zrozumieć rozkład danych. Kwartyli są trzy:

1. Pierwszy kwartyl (Q1) - 25% danych jest mniejszych lub równych tej wartości.
2. Drugi kwartyl (Q2) - to samo co mediana, 50% danych jest mniejszych lub równych tej wartości.
3. Trzeci kwartyl (Q3) - 75% danych jest mniejszych lub równych tej wartości.

Jak obliczyć kwartyle?

1. Posortuj dane w rosnącej kolejności.
2. Znajdź drugi kwartyl (Q2):
   - Jeśli liczba danych jest nieparzysta, mediana to środkowa wartość zbioru.
   - Jeśli liczba danych jest parzysta, mediana to średnia arytmetyczna dwóch środkowych wartości.
3. Znajdź pierwszy kwartyl (Q1): Pierwszy kwartyl to mediana dolnej połowy danych, czyli tych, które są mniejsze niż Q2.
4. Znajdź trzeci kwartyl (Q3): Trzeci kwartyl to mediana górnej połowy danych, czyli tych, które są większe niż Q2.

Wariancja określa rozrzut wyników wokół wartości średniej.
Odchylenie standardowe**:** miara niepewności pojedynczego pomiaru w serii. To pierwiastek z wariancji:

$$\sigma_x = \sqrt{\frac{\sum_{i=1}^{n}(x_i - \bar{x})^2}{n-1}}$$

Odchylenia standardowego średniej (błąd standardowy średniej) to odchylenie standardowe (s) podzielone przez pierwiastek z liczby pomiarów (n).

$$SE = \frac{s}{\sqrt{n}}$$

Cel

Celem tego ćwiczenia jest nabycie umiejętności przeprowadzania podstawowych analiz statystycznych z wykorzystaniem programu Microsoft Excel. Studenci nauczą się:

1. Tworzenia zestawień danych medycznych w arkuszu kalkulacyjnym.
2. Obliczania podstawowych miar statystycznych, takich jak średnia, mediana, odchylenie standardowe czy kwartyle.
3. Wizualizacji danych medycznych przy użyciu wykresów, takich jak histogramy, wykresy liniowe i pudełkowe (boxploty).
4. Interpretacji wyników analizy statystycznej w kontekście badań medycznych.

Przebieg ćwiczenia

1. Statystyka opisowa

Odszukaj zedytowany przez Ciebie plik BMI_cw3.xlsx z poprzedniego zadania (Zadanie 1 Ćwiczenia 3), gdzie policzone zostały wskaźniki BMI.

a) Wykonaj statystykę opisową policzonych w poprzednim zadaniu wskaźników BMI.
   i. Policz średnią, medianę i modę. Poszczególne wyrażenia w Excelu to: ŚREDNIA(dane) [AVERAGE], MEDIANA(dane) [MEDIAN], WYST.NAJCZĘŚCIEJ.WART(dane) [MODE.SNGL].
   ii. Policz błąd standardowy, odchylenie standardowe, wariancję. Użyj wyrażeń w Excelu: ODCH.STANDARD.PRÓBKI(dane) [STDEV.S], WARIANCJA.PRÓBKI(dane) [VAR.S]. Błąd standardowy to odchylenie standardowe podzielone przez pierwiastek z liczby pomiarów (patrz Wstęp). Wariancja to odchylenie standardowe podniesione do kwadratu.
   iii. Policz wszystkie trzy kwartyle: KWARTYL.PRZEDZ.ZAMK(dane;numer) [QUARTILE.INC], gdzie numery 1-3 to numery kwartyli natomiast 0 oraz 4 to wartości min i max.
   iv. Podobnie jak w poprzednim zadaniu (Zad. 1 w ćwiczeniu 3) stwórz histogram (użyj wykresu kolumnowego 2d) ale tym razem z większą liczbą kategorii od 20 do 38 co 3. Przepisz więc następującą kolumnę (zaznaczoną na czerwono) i użyj funkcji CZĘSTOŚĆ [FREQUENCY]:

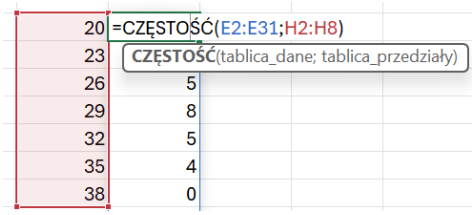

Narysuj wykres kolumnowy (2D) gdzie etykietami będą granicie podziałów (20-38) i dodaj na wykresie słupki błędów pokazujące błąd standardowy:



v. Sprawdź zgodność policzonych przez Ciebie statystyk z wynikami uzyskanymi przez użycie Analizy danych z dodatku Analysis ToolPak. Sprawdź czy dodatek jest włączony (podobnie jak Solver) klikając Plik->Opcje->Dodatki->Przejdź

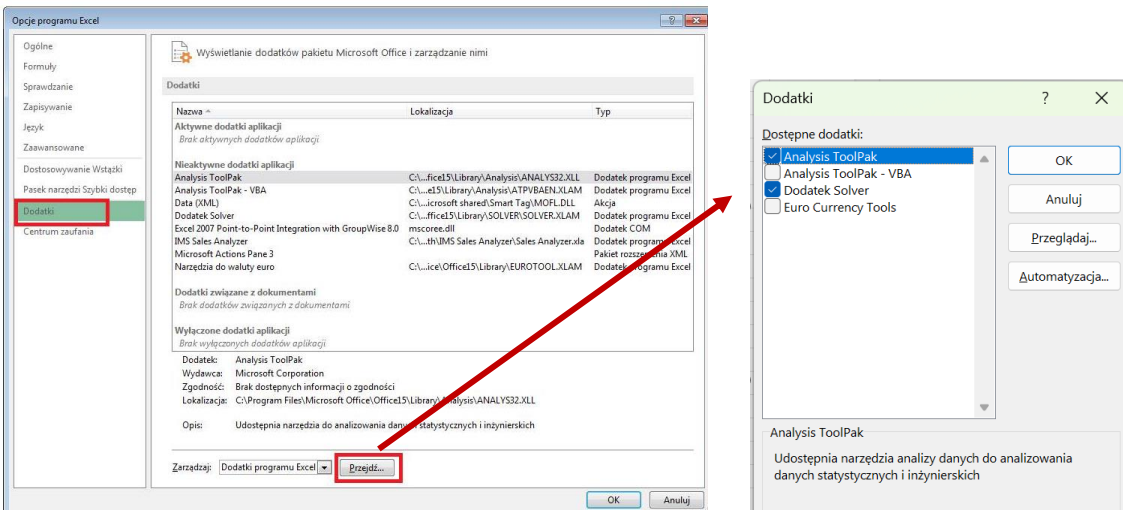

Następnie odszukaj na wstążce opcję: Dane->Analiza danych i wybierz „Statystyka opisowa” dla kolumny BMI. Wyniki analizy możesz umieścić na osobnym arkuszu lub we wskazanym w polu „Zakres wyjściowy” miejscu, np.:

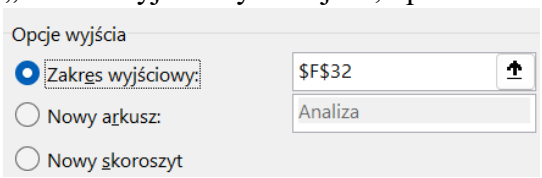

Zaznacz checkbox „**Statystyka podsumowująca**” i dopiero wtedy kliknij „OK”.

b) Stwórz wykres pudełkowy z uwzględnieniem mediany dla wartości BMI. W tym celu zaznacz dane (kolumna z BMI) i wstaw wykres „Skrzynka i wąsy". Dodaj etykiety danych (klikając + koło wykresu jak pokazano powyżej), oraz sformatuj wykres jak poniżej:

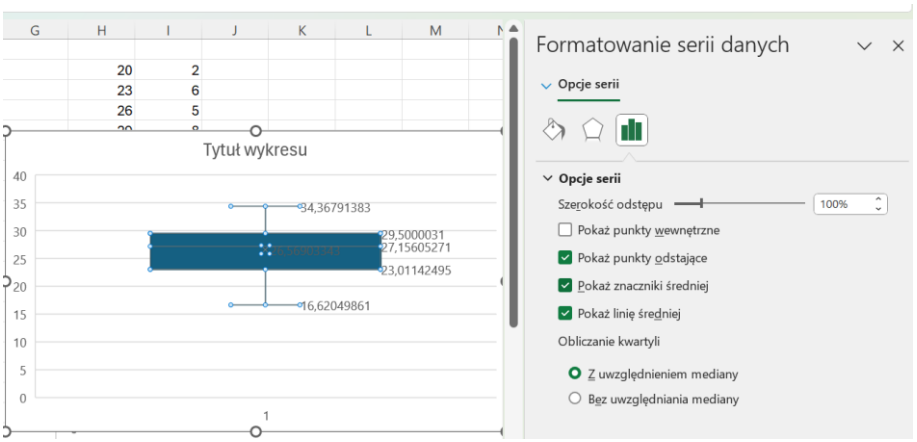

a) Rozsegreguj powyższe dane na 2 tabele: kobiety i mężczyźni i stwórz wykres jak powyżej pokazując wykres pudełkowy dla kobiet i mężczyzn aby porównać ich BMI. Do rozsegregowania użyjemy tabeli przestawnej:

1. Zaznacz całą tabelę danych (włącznie z nagłówkami). Użyj: Wstawianie->Tabela przestawna.
2. W oknie dialogowym wybierz, gdzie chcesz umieścić tabelę przestawną (np. na nowym arkuszu) i kliknij OK.
3. W polach tabeli przestawnej po prawej stronie:
   - Przeciągnij **"Płeć"** oraz „**BMI**" do obszaru **Wiersze**.

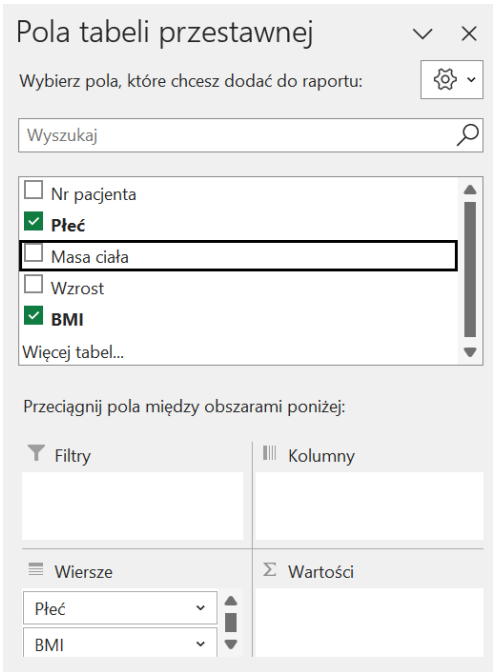

4. Skopiuj dane poza tabele przestawną, tak, aby dane utworzyły dwie kolumny (jedna dla kobiet i druga dla mężczyzn) a następnie stwórz wykres pudełkowy jak poprzednio:

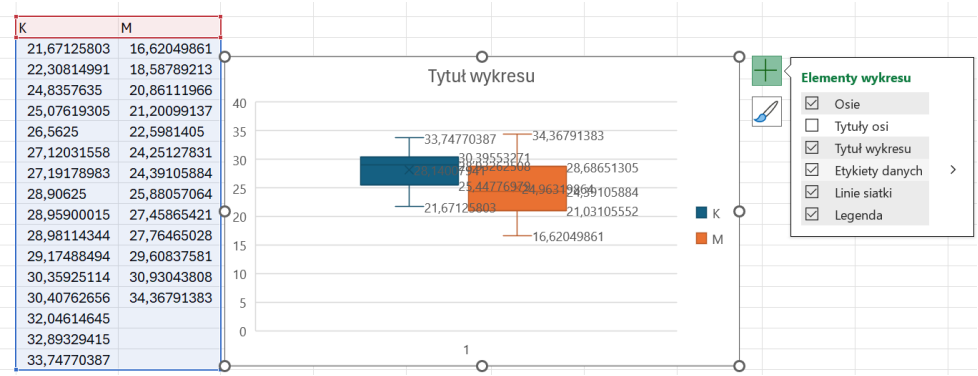

Dodaj do wykresu legendę oraz etykiety danych.
Zaznacz etykiety danych na wykresie i zmień format liczb na liczbowe z 2 miejscami po przecinku:

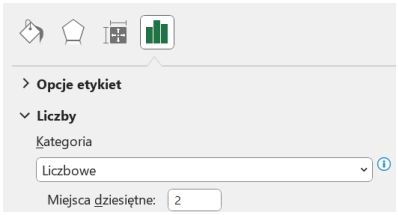

Przeanalizuj jakie różnice widzisz między kobietami i mężczyznami.

b) Wykonaj statystykę opisową (Dane->Analiza danych) osobno dla kobiet i mężczyzn na wspólnym Arkuszu również w celu porównania wyników.

2. Tabele przestawne

Pobierz plik dane_cw4.xlsx (link do pliku poda prowadzący) i zapisz go na własną nazwę np. NAZWISKO_IMIĘ_WM_ĆW4.xlsx

a) Zaznacz dane (włącznie z nagłówkami) i wstaw tabelę przestawną(Wstawianie->Tabela przestawna).

b) Podsumowanie liczby pacjentów na oddziałach (uwaga: nie klikaj nazw nagłówków tylko przeciągnij i upuść):
   - Umieść (przeciągnij i upuść) "Oddział" w wierszach tabeli przestawnej.
   - Umieść "Pacjent ID" w wartościach tabeli, licząc pacjentów (zmień z sumowania na „Liczba z Pacjent ID”).

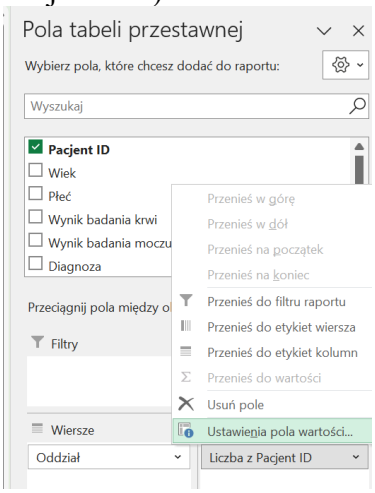

Odkopiuj rozsortowaną tabelę obok, żeby móc pracować nad kolejnym zadaniem na tabeli przestawnej. Usuń wybrane wcześniej pola z wierszy i wartości, żeby otrzymać pustą listę.

c) Średni wynik badania krwi w zależności od płci:
   - Umieść (przeciągnij i upuść) "Płeć" w wierszach tabeli przestawnej.
   - Umieść "Wynik badania krwi" w wartościach tabeli przestawnej, ustawiając jako średnią (nie sumę).

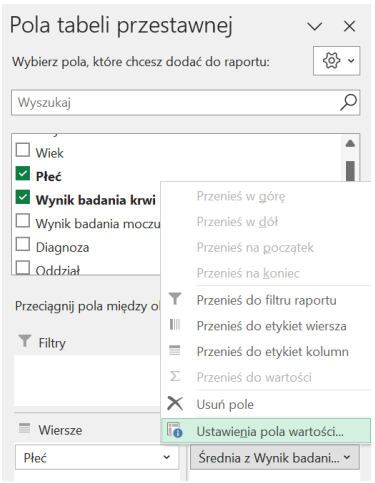

Odkopiuj tabelę obok, żeby móc pracować nad kolejnym zadaniem.

d) Średni czas hospitalizacji dla każdej diagnozy:
   - Umieść "Diagnoza" w wierszach tabeli przestawnej.
   - Umieść "Czas hospitalizacji (dni)" w wartościach, ustawiając jako średnią.

   Odkopiuj tabelę obok, żeby móc pracować nad kolejnym zadaniem.

e) Rozkład diagnoz pacjentów w zależności od oddziału:
   - Umieść "Oddział" w wierszach, a "Diagnoza" w kolumnach tabeli przestawnej.
   - Umieść "Pacjent ID" w wartościach, licząc pacjentów.

   Zaproponuj reprezentację graficzną: wykres, aby pokazać powyższy rozkład.

f) Filtr danych:
   - Skorzystaj z filtrów tabeli przestawnej, aby wyświetlić dane tylko dla kobiet lub mężczyzn. Do tego celu wstaw pole Płeć w obszar „Filtry”.

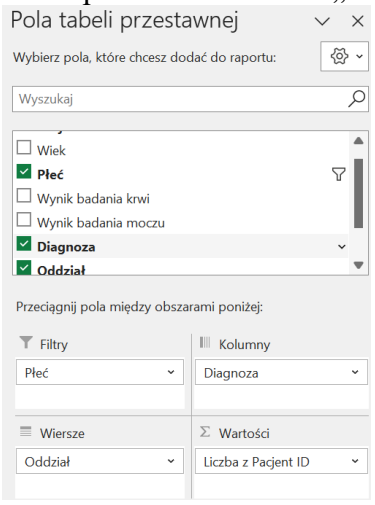

3. Elementy statystyki: częstość i kumulacja

Na pewnej uczelni postanowiono zbadać, z jak licznych rodzin pochodzą studenci. Przeprowadzono zatem badanie polegające na zapytaniu każdego studenta, ile ma rodzeństwa. Do podanej liczby rodzeństwa dodano **1**, ponieważ student jest również dzieckiem w swojej rodzinie. Okazało się, że największa liczba rodzeństwa wynosiła cztery, co oznacza, że rozpiętość wartości badanej cechy (liczby dzieci w rodzinie) wynosi od jeden do pięciu. Jest to zmienna ilościowa dyskretna.

Otrzymane dane przedstawiono już w postaci szeregu rozdzielczego. Oznacza to, że tabela nie zawiera pojedynczych odpowiedzi studentów, lecz informację, ilu studentów przypada na każdą wartość cechy.

Przepisz i uzupełnij poniższą tabelę, gdzie:

- Wartość cechy: cecha - liczba dzieci w rodzinie, wartości cechy – 1 do 5
- Liczebność: liczba studentów, dla których dana wartość cechy występuje,
- Częstość – udział danej cechy w całej badanej grupie (**częstość = liczebność / N** gdzie N oznacza łączną liczbę badanych studentów, czyli sumę wszystkich liczebności),
- Częstość [%] – częstość wyrażona w procentach,
- Kumulacja liczebności – suma liczebności od najmniejszej wartości cechy do danej wartości,
- Kumulacja częstości – suma częstości od najmniejszej wartości cechy do danej wartości. Jest to wartość dystrybuanty empirycznej.

	A	B	C	D	E	F
1	Wartość cechy	Liczebność	Częstość	Częstość [%]	Kumulacja liczebności	Kumulacja częstości
2	1	892				
3	2	1157				
4	3	798				
5	4	435				
6	5	121				
7	Razem					

Wykonaj:

- wykres kolumnowy przedstawiający liczebności,
- wykres kolumnowy przedstawiający częstości [%],
- wykres kołowy przedstawiający udział poszczególnych kategorii,
- wykres przedstawiający częstość skumulowaną (dystrybuantę empiryczną).

Uwaga: ponieważ liczba dzieci w rodzinie jest zmienną dyskretną, w tym ćwiczeniu wykres kolumnowy jest bardziej naturalny niż klasyczny histogram.

Odpowiedz na pytania:
- Jakiego typu zmienną jest badana cecha?
- Jaki kształt ma rozkład? Oceń go tylko wizualnie bez używania testów statystycznych.
- Czy w tym badaniu występuje zmienna zależna i niezależna?
- Ilu studentów pochodziło z rodzin wielodzietnych (liczących co najmniej 3 dzieci)?

4. Rozkłady

a) W pewnym szpitalu oddział ratunkowy przyjmuje średnio 3 pacjentów z zawałem serca na dobę. Załóż, że liczba pacjentów z zawałem serca, którzy trafiają na oddział ratunkowy, jest zmienną losową o rozkładzie Poissona.
Przypomnienie**:**
Rozkład Poissona opisuje prawdopodobieństwo wystąpienia pewnej liczby zdarzeń w określonym czasie, gdy znana jest średnia liczba tych zdarzeń (w tym przypadku średnia liczba pacjentów).
   a) Jakie jest prawdopodobieństwo, że w ciągu jednego dnia na oddział ratunkowy trafi dokładnie 5 pacjentów z zawałem serca?
   Odp: Policz rozkład dla średniej 3 i liczby szukanej 5
   =ROZKŁ.POISSON(5;3;0) [POISSON.DIST]
   Uwaga: zamiast 0 można napisać: Fałsz
   b) Jakie jest prawdopodobieństwo, że w ciągu jednego dnia na oddział ratunkowy trafi 2 lub mniej pacjentów z zawałem serca?
   Sposób 1: Policz rozkład dla liczby pacjentów <=2 czyli 0,1 oraz 2. Następnie zsumuj te prawdopodobieństwa.

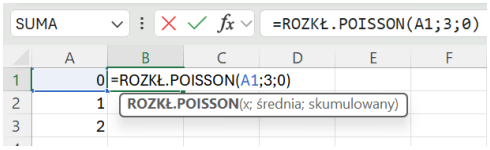

   Sposób 2: Użyj funkcji skumulowanej - dystrybuanty (ostatni parametr ustaw na 1), czyli**:** **=ROZKŁ.POISSON(2;3;1)** [POISSON.DIST]
   Uwaga: zamiast 1 można napisać: Prawda
   c) Jakie jest prawdopodobieństwo, że w ciągu trzech dni na oddział ratunkowy trafi 9 pacjentów z zawałem serca?
   Odp: Policz jaka jest średnia liczba pacjentów w ciągu 3 dni i taką średnią wstaw w rozkład. Odp: 3*3=9 więc obliczamy: **=ROZKŁ.POISSON(9;9;0)** [POISSON.DIST]
   d) Narysuj rozkład i dystrybuantę (wykresy kolumnowe) w zakresie 0-10 dla tego przykładu.

b) Załóżmy, że masa ciała 8-letnich dzieci ma rozkład normalny z średnią μ=25 kg i odchyleniem standardowym σ=4 kg.
   a) Jakie jest prawdopodobieństwo, że losowo wybrane 8-letnie dziecko będzie miało masę ciała mniejszą niż 30 kg?
   Odp: Szukamy dystrybuanty rozkładu normalnego:
   =ROZKŁ.NORMALNY(30;25;4;1) [NORM.DIST]
   Uwaga: Jeśli na końcu parametru podamy 0 zamiast 1 to otrzymamy rozkład a nie dystrybuantę czyli otrzymamy odpowiedz jakie jest prawdopodobieństwo że losowo wybrane dziecko waży dokładnie 30 kg.
   b) Jakie jest prawdopodobieństwo, że losowo wybrane 8-letnie dziecko będzie miało masę ciała większą niż 30 kg?
   Odp: odwracamy prawdopodobieństwo, czyli odejmujemy od jedynki wynik poprzedniego zadania: **=1-ROZKŁ.NORMALNY(30;25;4;1)** [NORM.DIST]