

WYDZIAŁ INŻYNIERII ZARZĄDZANIA

POLITECHNIKA POZNAŃSKA

ROZPRAWA DOKTORSKA

ALGORYTM HARMONOGRAMOWANIA PROCESÓW ZACHODZĄCYCH W ORGANIZACJI WSPOMAGANY SYSTEMAMI INFORMATYCZNYMI

ALGORITHM FOR SCHEDULING PROCESSES IN THE ORGANIZATION SUPPORTED BY IT SYSTEMS

mgr. inż. Aliaksandr LIAUSHUK

Promotor:

dr hab. inż. Aleksandra JASIAK

Promotor pomocniczy:

dr inż. Marek MATULEWSKI

Poznań 2020

Spis treści

Streszczenie ……..…….....4

Summary…….….6

Аннотация …….……8

Wykaz ważnych oznaczeń i skrótów ……10

1. Wprowadzenie……12
2. Cel i zakres pracy……..14

2.1 Cele……...……14

2.2 Uzasadnienie wyboru tematyki pracy……...……...15

2.3 Tezy rozprawy……..16

2.4 Aspekty praktyczne……..17

3. Charakterystyka badań……...18
4. Opis metod wykorzystanych do badań……...19
5. Charakterystyka podmiotu gospodarczego……26
6. Zasada działania laboratorium przyszpitalnego…….29

6.1 Charakterystyka procesów w wirowni……..31

6.2 Charakterystyka procesów w pracowni biochemii……...32

6.3 Charakterystyka procesów w pracowni krzepnięcia…...……34

6.4 Charakterystyka procesów w pracowni morfologii……..35

6.5 Charakterystyka procesów w rejestracji……36

6.6 Charakterystyka i analiza przepływu danych w poszczególnych pracowniach……..38

7. Zasada działania Big Data……..39

7.1 Tensor, zastosowanie w Big Data ……..…..…...43

7.2 Sieci neuronowe ……..……..……...45

8. Procedura badań…….49

8.1 Analiza danych diagramem przepływu danych……..…..49

8.2 Analiza danych teorią kolejek…….……....54

9. Specyfika wykorzystania danych metod w laboratorium……..57
10.Konstrukcja modelu matematycznego……...58
11. Przetestowanie wyników prognozy w badanym podmiocie gospodarczym…….87
12.Zastosowanie modelu matematycznego w przedsiębiorstwie produkcyjnym……....87
13. Algorytm harmonogramowania procesów……..…100
14.Zastosowanie modelu w warunkach przemysłowych…… 102
15.Wnioski z badań……...104
16.Kierunki dalszych badań……..106
Literatura……...108
Spis rysunków…….. 113
Spis wzorów……...…….. 115
Spis źródeł rysunków……... 116

STRESZCZENIE

W pracy przedstawione są zagadnienia związane z opracowaniem metody służącej do uporządkowania przepływu danych w podmiocie gospodarczym przy wykorzystaniu diagramu przepływu danych i teorii kolejek. Celem pracy jest stworzenie algorytmu harmonogramowania procesów zachodzących w organizacji wspomaganego systemami informatycznymi.

Realizując założony cel dokonano szereg analiz. Pod tym względem prace podzielono na kilka etapów.

W pierwszym etapie pracy zostały przybliżone zagadnienia dotyczące metod zastosowanych w pracy oraz charakterystyki badanego podmiotu gospodarczego.

W drugim etapie pracy podmiot gospodarczy został przeanalizowany przy pomocy teorii kolejek i diagramu przepływu danych. Do wizualizowania procesów zachodzących w podmiocie gospodarczym zastosowano diagram przepływu danych. Za pomocą teorii kolejek zostały wyznaczone najsłabsze punkty w przepływie danych podmiotu gospodarczego.

W trzecim etapie pracy autor skupił się na analizie i uporządkowaniu danych uzyskanych w podmiocie gospodarczym oraz na opracowaniu modelu matematycznego który umożliwi prognozowanie obciążenia na kolejne dni, identyfikację powiązań pomiędzy warunkami eksploatacji i doskonaleniem systemu zarządzania warunkami pracy.

W czwartym etapie pracy na podstawie wykonanych czynności sprecyzowano algorytm harmonogramowania procesów oraz przetestowano uzyskane prognozy z rzeczywistymi danymi podmiotu gospodarczego.

W piątym etapie pracy algorytm harmonogramowania zastosowano w podmiotach gospodarczych działających w diametralnie innej branży.

Uzyskane przez autora w ramach pracy doktorskiej wyniki znacząco pogłębiają wiedzę o zastosowaniu podobnych rozwiązań, które korzystają z metod zastosowanych w tej pracy.

Słowa kluczowe: przepływ danych, informacja, teoria kolejek, podmiot gospodarczy, harmonogramowanie procesów, systemy informatyczne.

SUMMARY

The thesis presents aspects connected with the development of a method of arrangement of the flow of data through a business entity using a data-flow diagram and queueing theory. The objective of this thesis is to design a scheduling algorithm for processes inside a computer aided organisation.

A series of analyses was carried out for the purposes of the assumed objective. For this purpose, the study was divided into several stages.

The first stage presented aspects related to the methods used for the purposes of the study and the profile of the investigated business entity.

As part of the second stage, the queueing theory and a data-flow diagram were used to analyse the business entity. The processes inside the business entity were visualised using a data-flow diagram. The weakest links of the data flow system of the business entity were defined using the queueing theory.

The third stage of the dissertation consisted of the analysis and arrangement of the data obtained from the business entity and development of a mathematical model which would allow to forecast the workload in the upcoming days, identify the links between the conditions of operation and the development of the working conditions management system.

In the course of the fourth stage, the performed operations were used to define a process scheduling algorithm and compare the forecasts with the actual data obtained from the business entity.

As part of the fifth stage, the scheduling algorithm was applied for business entities operating in completely different industries.

The results achieved by the author in the course of the dissertation serve as a significant development of the knowledge of the use of similar solutions, which encompass the methods used in this study.

Key words: data flow, information, queueing theory, business entity, process scheduling, IT systems.

АННОТАЦИЯ

В работе представлены вопросы, связанные с разработкой метода предназначенного для упорядочивания потока данных на предприятии с использованием диаграммы потока данных и теории очередей. Целью работы является создание алгоритма планирования процессов в организации, при поддержке информационных систем.

Реализуя поставленную цель, был проведен ряд анализов. По этому принципу работа разделена на несколько этапов.

На первом этапе работы обсуждались вопросы относительно методов, используемых в работе, и характеристик предприятия.

На втором этапе работы предприятие было проанализировано при помощи теории очередей и диаграммы потока данных. Для визуализации процессов, происходящих в предприятии использовался диаграмм потока данных. При помощи теории очередей были обозначены самые слабые места в потоке данных предприятия.

На третьем этапе работы автор сосредоточился на анализе и упорядочении данных, полученных на предприятии и в исследовании математической модели, которая позволит прогнозировать нагрузку на следующие дни, выявление связей между условиями эксплуатации и совершенствованием системы управления условиями труда.

На четвертом этапе работы на основе выполненных заданий был сформулирован алгоритм планирования процесса и полученные прогнозы были проверены с фактическими данными предприятия.

На пятом этапе работы алгоритм планирования был использован на предприятии, работающим в совершенно другой отрасли.

Результаты, полученные мной в рамках моей докторской диссертации, значительно углубляют знания об эксплуатации аналогичных решений, которые используют методы, применённые в это работе.

Ключевые слова: поток данных, информация, теория очередей, коммерческое предприятие, планирование процессов, информационные системы.

WYKAZ WAŻNYCH OZNACZEŃ I SKRÓTÓW

1. DFD - Data Flow Diagram
2. AspAT -Aminotransferaza asparaginianowa
3. ALT - Aminotransferaza alaninowa
4. GGT - glutamylotransferaza
5. CK - kinaza keratynowa
6. LDH - dehydrogenaza mleczanowa
7. TSH - hormon tyreotropowy
8. T4 - aktywna forma tyroksyny
9. TG – trójglicerdydy
10. HDL - lipoproteina o wysokiej gęstości
11. LDL - lipoproteina o niskiej gęstości
12. WBC – leukocyty
13. RBC – erytrocyty
14. HGB – hemoglobina
15. MCV - średnia objętość czerwonej krwinki
16. RDW - rozkład objętości krwinek czerwonych
17. HCT – hematokryt
18. MCH - średnia masa hemoglobiny w krwince
19. MCHC - średnie stężenie hemoglobiny w krwince
20. PLT – trombocyty
21. LYMPH %- limfocyty (odsetek procentowy)
22. EOS% - eozynofile (odsetek procentowy)
23. BASO% - bazofile (odsetek procentowy)
24. NEUT% - neutrofile (odsetek procentowy)
25. MONO %- monocyty (odsetek procentowy)
26. LYMPH #- limfocyty (liczba bezwzględna limfocytów)
27. EOS#- eozynofile (liczba bezwzględna eozynofili)
28. BASO# - bazofile (liczba bezwzględna bazofili)
29. NEUT# - neutrofile (liczba bezwzględna neutrofili)
30. MONO#- monocyty (liczba bezwzględna monocytów)
31. IT - information technology
32. IBM - International Business Machines Corporation
33. SAS – Analytics Software & Solutions
34. XML - Extensible Markup Language

35. EDI - Electronic Data Interchange
36. PDF - Portable Document Format
37. TXT - podstawowy format zapisu plików tekstowych
38. EFA - eksploracyjna analiza czynnikowa
39. CFA - konfirmacyjna analiza czynnikowa
40. PSA - Prostate Specific Antygen

1. WPROWADZENIE

W niniejszej pracy autor skupił się na opracowaniu metody uporządkowania i usprawnienia przepływu danych w wybranym, branżowym podmiocie gospodarczym. W opracowaniu zostały wykorzystane dane uzyskane w laboratorium medycznym w szpitalu klinicznym. Problematyka badań polega na ujawnieniu istniejących zależności organizacyjno-technicznych funkcjonowania laboratorium pod wpływem różnych czynników takich jak: czynniki technologiczne, ludzkie czy też finansowe oraz znalezienie sposobu zwiększenia efektywności jego działania Autor pracy stwierdza na podstawie przeprowadzonych studiów literaturowych, posiadanej wiedzy oraz własnych doświadczeń, że na świecie brakuje podobnych rozwiązań, które korzystają z metod zastosowanych w tej pracy. W analizowanym laboratorium znajdują się analizatory (urządzenia technologiczne), które obsługują diagności laboratoryjni w ciągu jednej zmiany. Analizatory służą do oznaczania wyników ilościowych i jakościowych badanych próbek materiału biologicznego. Celem badań jest wyznaczenie „wąskich gardeł" w trakcie przepływu próbek przez laboratorium. Główny proces realizowany w laboratorium polega na przeprowadzaniu różnego rodzaju operacji technologicznych. Ich fizyczna realizacja zależy od bardzo skomplikowanych reakcji chemicznych i fizycznych mających miejsca podczas wykonywania zleconych analiza laboratoryjnych. Reakcje w badaniach klinicznych są uzależnione biologicznie i na czas ich przebiegu nie mamy dużego wpływu. Analizatory wykorzystywane w laboratorium posiadają wysoki poziom technologiczny a technologie badań cały czas się doskonalą. Tworzenie procedury zdaniem autora powinno być skierowane na procesy pomocnicze i powinno się zacząć od wyznaczenia czasu, kiedy w ciągu dnia pojawiają się największe kolejki próbek do analizy i przyczyn powodujących kolejkowanie. Powstające kolejki sygnalizują o nierównomiernym obciążeniu analizatorów i pracowników. Stabilizacja obciążenia analizatorów oraz rytmiczność pracy diagnostów laboratoryjnych zwiększa efektywność wykorzystania analizatorów, jednocześnie zmniejsza zużycie odczynników reakcyjnych i ilość błędnych badań (Liaushuk A., 2017). W niniejszej pracy autor skupił się na stworzeniu uniwersalnego algorytmu harmonogramowania procesów, który

został przetestowany w opraciu o dane uzyskane w laboratorium. Ponadto algorytm ten został dodatkowo przetestowany w przedsiębiorstwie produkcyjnym zajmującym się obróbka blach oraz w przedsiębiorstwach o podobnej branży.

2. CEL I ZAKRES PRACY

2.1 Cele

Głównym celem pracy jest opracowanie uniwersalnej metody, za pomocą której można uporządkować przepływ danych w wybranym podmiocie gospodarczym stosując diagram przepływu danych i teorię kolejek.

Cel główny autor zrealizował drogą następujących celów szczegółowych:

- Stworzenie modelu umożliwiającego prognozowanie obciążenia na kolejne dni.
- Identyfikację powiązań pomiędzy warunkami eksploatacji i doskonaleniem systemu zarządzania warunkami pracy.
- Stworzenie modelu optymalizacji procesów zachodzących w przedsiębiorstwie, opartego na teorii kolejek i diagramie przepływu danych pozwalających uzyskać rytmiczność pracy.
- Określenie miar pozwalających w sposób wymierny określić zysk dla przedsiębiorstw, wynikający z zastosowania tego rodzaju modeli optymalizacji procesów.

2.2 Uzasadnienie wyboru tematu

W warunkach turbulentnego otoczenia, a więc dynamicznych i głębokich zmian czynników zewnętrznych, o przetrwaniu organizacji na rynku decydować będzie m.in. jej elastyczność i zdolność do adaptacji i wprowadzania zmian. Oznacza to, że na wartości zyskują przede wszystkim przedsiębiorstwa, które potrafią prawidłowo zorganizować i optymizować procesy produkcyjne lub usługowe, przekształcając potencjał przedsiębiorstwa w unikatowe z punktu widzenia klienta produkty lub usługi. Zmiany, w tym: procesy globalizacji, rosnąca rola tworzenia korzystnych powiązań z otoczeniem, czy narastająca rywalizacja o pozycję rynkową w warunkach gospodarki sprawiają, że w przedsiębiorstwach poszukuje się nowych sposobów zarządzania przepływami danych i optymizacji pracy. Aktualnym przykładem czynnika zewnętrznego jest COVID-19 (ang. Coronavirus Disease 2019) który miał znaczący wpływ na gospodarkę światową i dla dużej liczby przedsiębiorstw okazał się czynnikiem decydującym o przetrwaniu.

Kluczowe znaczenie zarządzania przepływami danych i optymizacji pracy dla rozwoju podmiotów gospodarczych można zauważyć zwłaszcza w sektorze produkcyjnym. Bezpośrednia efektywność pracy pracowników produkcji oraz odpowiednie zarządzanie parkiem maszynowym stanowi podstawę budowania trwałych relacji handlowych poprzez:

- terminowe dostarczanie zamówień,
- krótki czas realizacji zleceń,
- elastyczność i krótki czas w dostosowaniu się do zmieniających się wymagań klientów,
- niższe koszty itd.

Wdrożenia tego rodzaju rozwiązań w przedsiębiorstwie rodzą określone konsekwencje ekonomiczne, determinujące tworzenie unikatowej i pozytywnie wyróżniającej się w otoczeniu firmy. W związku z powyższym traktuje się narzędzia do optymalizacji pracy jako niezbędne zasoby, umożliwiające przedsiębiorstwu osiąganie określonych celów biznesowych.

2.3 Tezy rozprawy

Główną tezą pracy jest stwierdzenie mówiące o tym, że przy wykorzystaniu podstawowych danych uzyskanych w podmiocie gospodarczym można stworzyć algorytm harmonogramowania procesów zachodzących w organizacji wspomagany systemami informatycznymi, który pozwoli prognozować obciążenia i umożliwi stabilizację obciążeń maszyn oraz rytmiczność pracy zasobów ludzkich.

2.4 Aspekty praktyczne

Najczęstszym problemem pojawiającym się w trakcie tworzenia procedury powiększenia informacyjności jest nieodpowiednia forma generowanych danych. Pod pojęciem informacyjność należy dalej rozumieć stopień nasycenia źródła informacji pozyskanymi danymi. Dane, które można uzyskać w systemie rejestracji laboratorium i raportach generowanych przez analizatory niosą potrzebną informację wyłącznie dla pracowników laboratorium i lekarzy, lecz z punktu widzenia inżyniera nie są łatwe do analizy i nie posiadają potrzebnej formy zapisu. Najważniejszym ograniczeniem przy generowaniu raportów jest ochrona danych osobowych. Celem tych badań jest stworzenie metody umożliwiającej zwiększenie przepustowości i opracowanie procesu przetwarzania danych wejściowych, czyli informacje dla lekarzy na tzw. dane wyjściowe, które można wykorzystać w analizach matematyczno-statystycznych. Aspektem praktycznym jest wykorzystanie algorytmu harmonogramowania procesów zachodzących w wybranym podmiocie gospodarczym wspomaganym systemami informatycznymi w przedsiębiorstwach produkcyjnych.

3.CHARAKTERYSTYKA BADAŃ

Badania polegały na uzyskaniu danych z podmiotu gospodarczego, na podstawie których powstanie algorytm harmonogramowania procesów zachodzących w organizacji. Dane zostały wygenerowane w laboratorium klinicznym w szpitalu uniwersyteckim. Szpital przyjmuje w ciągu roku 40 tys. hospitalizowanych pacjentów i udziela ponad 200 tys. porad ambulatoryjnych. Na powierzchni 10 ha znajduje się 26 klinik i działów. Średnia liczba badań wykonywanych przez laboratorium wynosi około 700 sztuk dzienne. W trakcie badań w laboratorium wygenerowano 365 raportów dotyczących ilości zleconych badań przez każdą klinikę szpitala w jednym dniu. Biorąc pod uwagę średnią ilość badań wykonywanych w jednym dniu (średnio 700 badań), wygenerowane przez autora raporty posiadają 255 500 pozycji do analizy. Dane zostały wyczyszczone i przygotowane do analizy, tym samym tworząc Big Data. Przy pomocy sieci neuronowych, które analizowały dane umieszczone w Big Data wyznaczono i określono zależności, które maja największy wpływ na procesy zachodzące w laboratorium klinicznym. Na podstawie uzyskanych danych stworzono model, który pozwala na prognozowanie obciążeń w kolejnych dniach. Następnym krokiem było przetestowanie modelu na przykładzie laboratorium klinicznego oraz zastosowanie modelu w innych przedsiębiorstwach produkcyjnych.

4. OPIS METOD WYKORZYSTANYCH DO BADAŃ

W części utylitarnej autor skupił się na trzech metodach wykorzystanych do analizy danych. Autor korzysta z metod takich jak teoria kolejek, model przepływu danych oraz model transportowy. Poniżej szczegółowo zostały opisane poszczególne metody.

Teoria kolejek - teoria w badaniach operacyjnych oparta na rachunku prawdopodobieństwa, wykorzystywana do podejmowania optymalnych decyzji w sytuacjach tworzenia się kolejek *(Kopańska-Bródka D., 2006)*.

Teoria ta na płaszczyznę badań operacyjnych została przeniesiona z zastosowania jej elementów w praktyce wojennej. Problem kolejek był rozważany po raz pierwszy w odniesieniu do samolotów bombowych, które musiały lądować w krótkim czasie na ograniczonej liczbie lądowisk. Aby w prosty sposób wytłumaczyć czym się zajmuje teoria kolejek autor przytoczył najpopularniejszą sytuację, którą analizuje teoria kolejek, czyli powszechne tworzenie się kolejek w sklepach samoobsługowych. W momencie, gdy klient podchodzi do kasy może napotkać na dwie możliwe sytuacje: pierwsza, taka w której przed kasą nie ma kolejki i klient zostaje obsłużony od razu; druga w której przy kasie jest kolejka, klient musi ustawić się w niej i czekać. Kupujący zazwyczaj jest zadowolony, gdy nie musi czekać lub gdy okres oczekiwania jest krótki. Spowoduje to, że w przyszłości z większą chęcią (z większym prawdopodobieństwem) odwiedzi ten supermarket lub podmiot gospodarczy *(Kopańska-Bródka D., 2006)*.

Z drugiej strony, aby doprowadzić do sytuacji, w której każdy klient obsługiwany jest natychmiastowo, właściciel supermarketu musiałby zatrudniać dużą liczbę kasjerów i dodatkowo istniałaby możliwość, że przez dużą część czasu siedzieliby oni bezczynnie przy kasie czekając na klienta. Pracodawcy powinno zależeć na nieprzerwanej pracy kasjera, ponieważ byłoby to bardziej efektywne *(Kopańska-Bródka D., 2006)*.

Przed właścicielem stoi podjęcie decyzji co do ilości uruchomionych kas, która spowoduje, że klienci nie będą czekać zbyt długo, przy jednoczesnej nieprzerwanej pracy kasjerów.

Z teorią kolejek związane są określone pojęcia. Pierwszym z nich jest stopa przybycia (λ), a drugim - stopa obsługi (μ). Stopa przybycia to przeciętna liczba klientów przypadająca na jednostkę czasu, czyli określa ona jak

często klienci podchodzą do kasy. Stopa obsługi to przeciętna liczba klientów obsłużona w jednostce czasu. Dzieląc stopę przybycia przez stopę obsługi otrzymujemy parametr intensywności ruchu (ϱ), który mówi o ilości klientów, którzy podeszli do kasy i zostali obsłużeni w jednostce czasu. Możliwe są dwie sytuacje:

- pierwsza, gdy $\lambda < \mu$ - układ jest stabilny, prawdopodobieństwo tego, iż kolejka ma określoną długość, jest stałe w każdej jednostce czasu
- druga, gdy $\lambda \geq \mu$ układ jest niestabilny, prawdopodobieństwo długiej kolejki rośnie *(Kukuła K. 1998), (https://mfiles.pl)*

W niniejszej pracy kliniki pełnią rolę klientów a funkcję kas pełnią pracownie w laboratorium klinicznym.

Diagramy przepływu danych stanowią narzędzie opisu, analizy i projektowania systemów informatycznych, których geneza sięga pierwszych generacji systemów informatycznych (systemów transakcyjnych, wsadowych).
W sposób graficzny prezentują one podstawowe zależności zachodzące w procesach informacyjnych, przy czym ich zaletą jest maksymalne uproszczenie stosowanej symboliki *(https://mfiles.pl).*
Diagram przepływu danych (ang. Data Flow Diagram, DFD) jest grafem pokazującym związki zachodzące między wartościami wprowadzanymi, przetwarzanymi i wyprowadzanymi z systemu, poprzez pokazanie ich przepływów pomiędzy jego poszczególnymi procesami (modułami). DFD nie zajmuje się zależnościami czasowymi, nie jest w nim istotne, jakie jest następstwo aktywności lub związek przyczynowo-skutkowy pomiędzy czynnościami. Do składników diagramu DFD należą:

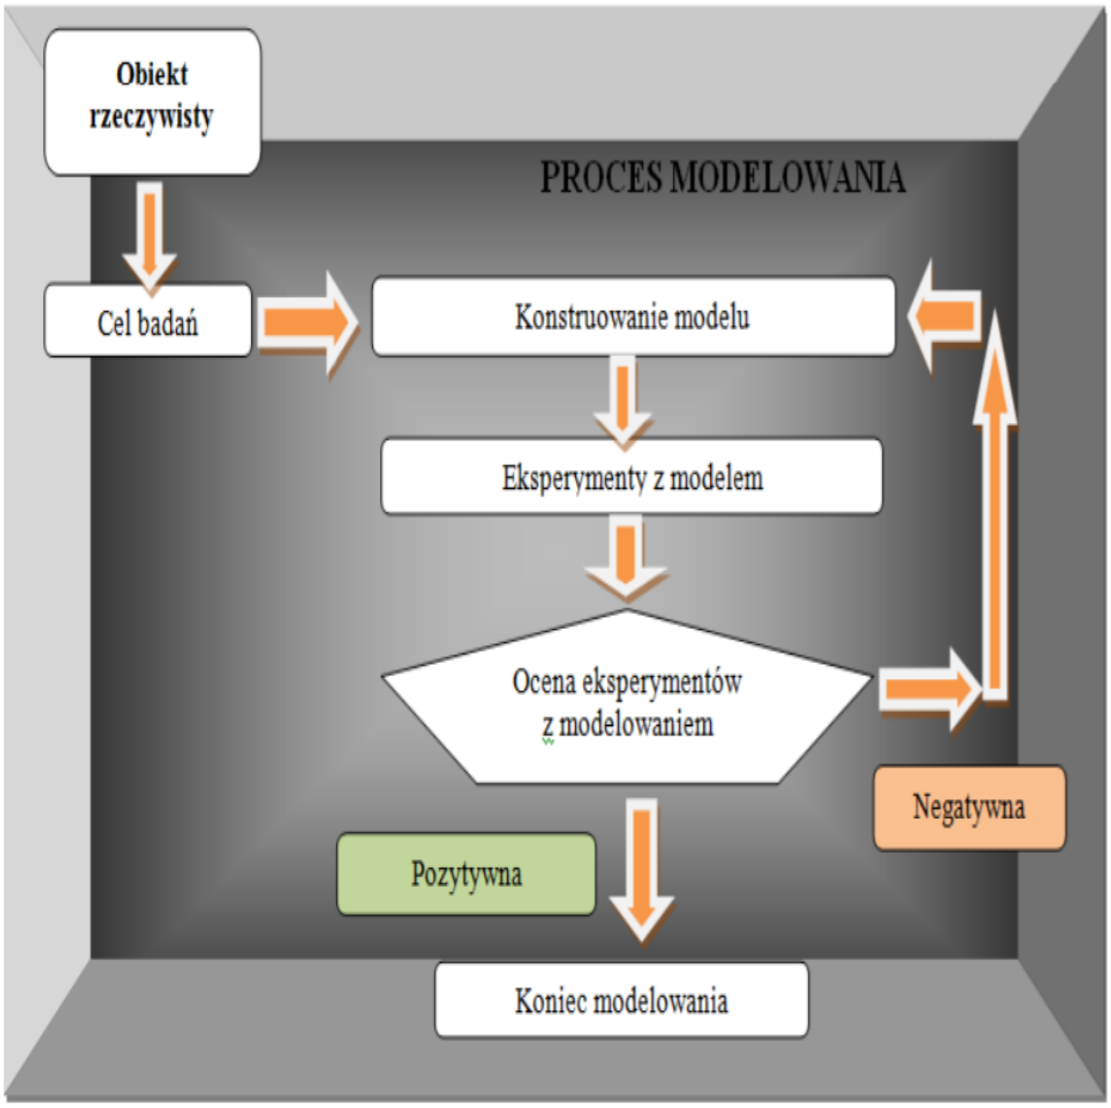
- Procesy –funkcje, procesy realizowane w systemie, przekształcające dane wejściowe w wyjściowe.
- Przepływy – reprezentują drogi przepływu i zawartość informacyjną danych przesyłanych od źródła do celu.
- Magazyny danych - reprezentują miejsca przechowywania w systemie częściowo lub całkowicie przetworzonych danych.
- Terminatory źródła lub miejsca przeznaczenia danych -zewnętrzne obiekty, z którym system się komunikuje, np. osoby, działy, jednostki organizacyjne.

DFD obrazuje za pomocą przepływów kierunek przepływu danych pomiędzy funkcjami, magazynami i obiektami zewnętrznymi. DFD mogą być prezentowane na różnych stopniach szczegółowości, można tu mówić o:

- Diagramach kontekstowych, które pokazują granice systemu, źródła i odbiorców danych oraz główne wejścia i wyjścia systemu. Przedstawia on powiązania procesu z jego otoczeniem, czyli kontekstem, w którym się funkcjonuje.
- Diagramach systemowych (zerowych), które przedstawiają główne zadania, grupy funkcjonalne lub procesowe systemu. Identyfikacja głównych procesów odbywa się w wyniku dekompozycji diagramu kontekstowego.
- Diagramach szczegółowych (procesów elementarnych), które pokazują szczegółowe realizacje funkcji systemowych.

Modelowanie jest procesem, oznaczającym działanie polegające na dobieraniu do oryginału reprezentatywnego możliwego do przyjęcia zamiennika zwanego modelem *(Jacyna M., 2009)*. W dziedzinie informatyki, modelowanie definiuje się jako doświadczalną lub matematyczną metodę badań złożonych układów, zjawisk i procesów na podstawie konstruowania modeli *(Walukiewicz S., 1986)*. Oprócz samego modelowania ważnym elementem jest również przeprowadzanie eksperymentów, związanych z tym modelem. Modelowanie doświadczalne opiera się na podobieństwie fizycznym, gdy badania przeprowadza się przy użyciu układów podobnych, ale w innej, najczęściej mniejszej skali. Natomiast modelowanie matematyczne opiera się na dobieraniu do oryginału zamiennika, odwzorowującego badaną rzeczywistość, zwaną modelem matematycznym, a następnie eksperymentowanie z tym modelem. Wynika stąd, że celem modelowania jest przede wszystkim uzyskanie informacji o rzeczywistym obiekcie a budowa modelu pozwala na osiągnięcie celu na podstawie przeprowadzonych eksperymentów na jego modelu. Celem modelowania systemu transportowego jest konstruowanie modelu, umożliwiającego poznanie zależności występujących w rzeczywistym obiekcie transportowym *(Jacyna M., 1997), (Jacyna M., 2009), (Mazur M., 1987)*. Model systemu transportowego oraz prowadzone z nim eksperymenty pozwalają na

poznanie tych zależności, tj. osiągnięcie celu modelowania *(Smogór-Szęszoł E., 2014)*.



Rys.1.Schemat procesu modelowania.
(Źródło:https://www.czasopismologistyka.p/ artykuly-naukowe/send/308-artykuly-na-plycie-cd-6/5171-artykul)

Obiektem modelowania może być dowolny fragment rzeczywistości transportowej. Cele, dla których buduje się modele systemów transportowych, mogą być przykładowo celami poznawczymi, jak np.:

- identyfikacja systemu;
- określenie związków między wielkościami występującymi w badanym systemie;
- określenie przebiegu zmienności wielkości, które mogą być przedmiotem (celem) badań.

Przedmiotem badań mogą być również cele utylitarne, sprowadzające się do *(Jacyna M., 2009):*

- poszukiwania rozwiązań optymalnych, np. rozłożenie potoku ruchu;
- analizy i oceny wariantu wyposażenia techniczno-organizacyjnego systemu transportowego;
- doboru do zgłaszanych potrzeb przewozowych najkorzystniejszego wyposażenia techniczno-organizacyjnego systemu transportowego;
- planowania zmian wyposażenia techniczno-organizacyjnego systemu transportowego;
- harmonogramowania przebiegu procesu transportowego przy realizacji określonych potrzeb przewozowych oraz przy ustalonym wyposażeniu techniczno-organizacyjnym systemu transportowego;
- sterowania przebiegiem procesu transportowego przy jego zadanym stanie początkowym, określonych wejściach i przyjętych kryteriach oceny jakości przebiegu procesu.

Nadrzędnym celem działania systemu transportowego jest przemieszczanie osób i (lub) ładunków, wynikające z rodzaju, liczby i cech przemieszczanych obiektów, jak również relacji przewozu oraz parametrów jakości (np.: bezpieczeństwa, szybkości, komfortu). Realizacja tego celu jest transformacją strumieni wejściowych w strumienie wyjściowe z systemu przy odpowiednim wyposażeniu systemu *(Jacyna M., 2009)*.

Głównym wejściem do systemu transportowego jest strumień – niezbędny do prawidłowego funkcjonowania systemu – środków uzbrojenia technicznego i organizacyjnego, tj. materiałów i energii, ponadto maszyn i urządzeń, zasobów siły roboczej, środków finansowych itp., a przede wszystkim potrzeb przewozowych zgłaszanych przez otoczenia *(Jacyna M., 2009)*.

Wyposażeniem systemu transportowego, niezbędnym do jego funkcjonowania, jest szeroko rozumiana suprastruktura (obejmuje urządzenia i instytucje bezpośrednio produkcyjne) i infrastruktura. Funkcjonowanie systemu jako sekwencja czynności składających się na realizację przemieszczania osób i ładunków, wynika ze współdziałania elementów infrastruktury i ludzi stanowiących załogę systemu transportowego.

Wyjście z systemu transportowego - to pożądane usytuowanie przestrzenne przemieszczanych obiektów, którego charakterystykę stanowi wielkość zrealizowanych potrzeb przewozowych wraz z oceną jakości ich realizacji.

Otoczenie systemu transportowego stanowią pozatransportowe działy gospodarki narodowej, społeczeństwo oraz środowisko naturalne *(Jacyna M., 2009)*.

Dlatego też dla wcześniej sformułowanego celu modelowania systemu transportowego powinny być zidentyfikowane istotne elementy systemu. Na potrzeby modelu niezbędna jest zatem, identyfikacja wejść do systemu, a następnie taka ich transformacja, aby ich wyjścia były optymalne ze względu na przyjęte kryteria.

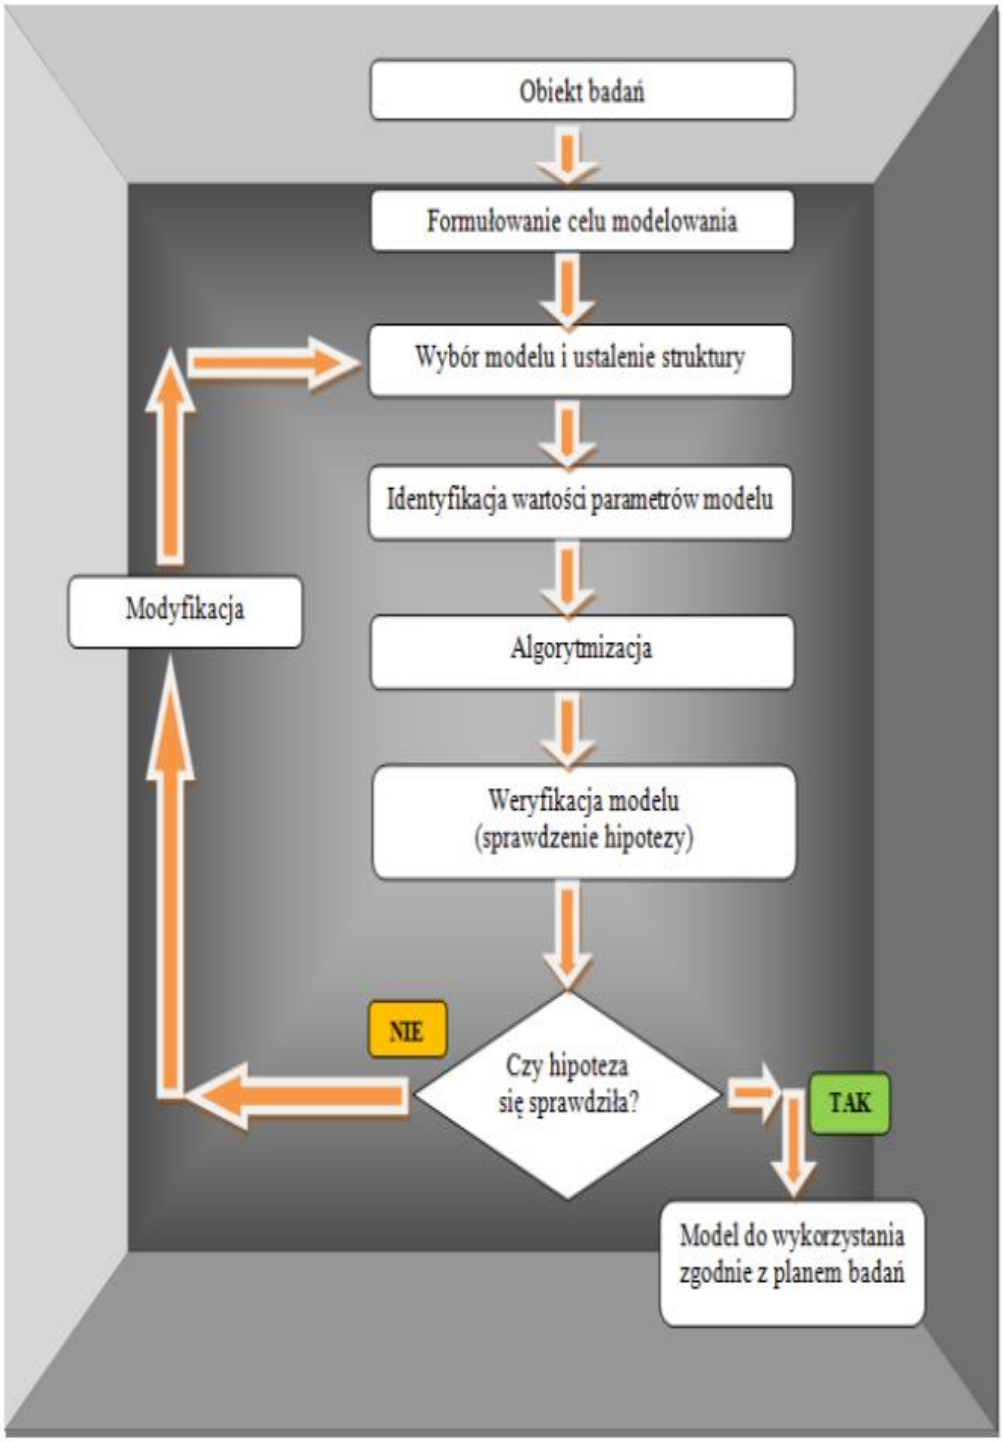
Konstruowanie modelu systemu transportowego zwykle poprzedzane jest określeniem celu modelowania. Cel badania systemu powinien być określony precyzyjnie i sformułowany w sposób ostateczny możliwie wcześnie. Określenie celu badań wyznacza pożądane kierunki badań oraz ogranicza zakres i stopień szczegółowości badań rzeczywistego systemu *(Smogór-Szęszoł E., 2014)*.

Proces osiągania celu modelowania można podzielić na następujące etapy:

1) formułowanie celu modelowania;
2) identyfikacja zmiennych i parametrów modelu;
3) zapis funkcji kryterium modelu, kwantyfikującej cel modelowania;
4) analityczny zapis ograniczeń modelu (struktura modelu);
5) algorytmizacja obliczeń;
6) weryfikacja obliczeń.

Struktura modelu porządkuje powiązania pomiędzy elementami modelu. Porządkowany jest również sam proces zbierania informacji, aż do ważnego momentu wyznaczenia wartości liczbowych parametrów uwzględnianych w opisie modelu. Oszacowanie tych wartości powinno odbywać się odpowiednią drogą, dążącą do przetworzenia danych. Po realizacji etapu identyfikacji elementów model znany jest z dokładnością do liczbowych wartości parametrów. Rysunek 2 przedstawia ogólną procedurę konstruowania wyżej opisanego modelu.

Algorytmizacja obliczeń może odnosić się do sformułowania zadania optymalizacyjnego oraz do wyznaczenia wartości parametrów



Rys. 2 Ogólna procedura konstruowania modelu.
(Źródło:https://www.czasopismologistyka.pl/artykuly-naukowe/send/308-artykuly-na-plycie-cd-6/5171-artykul)

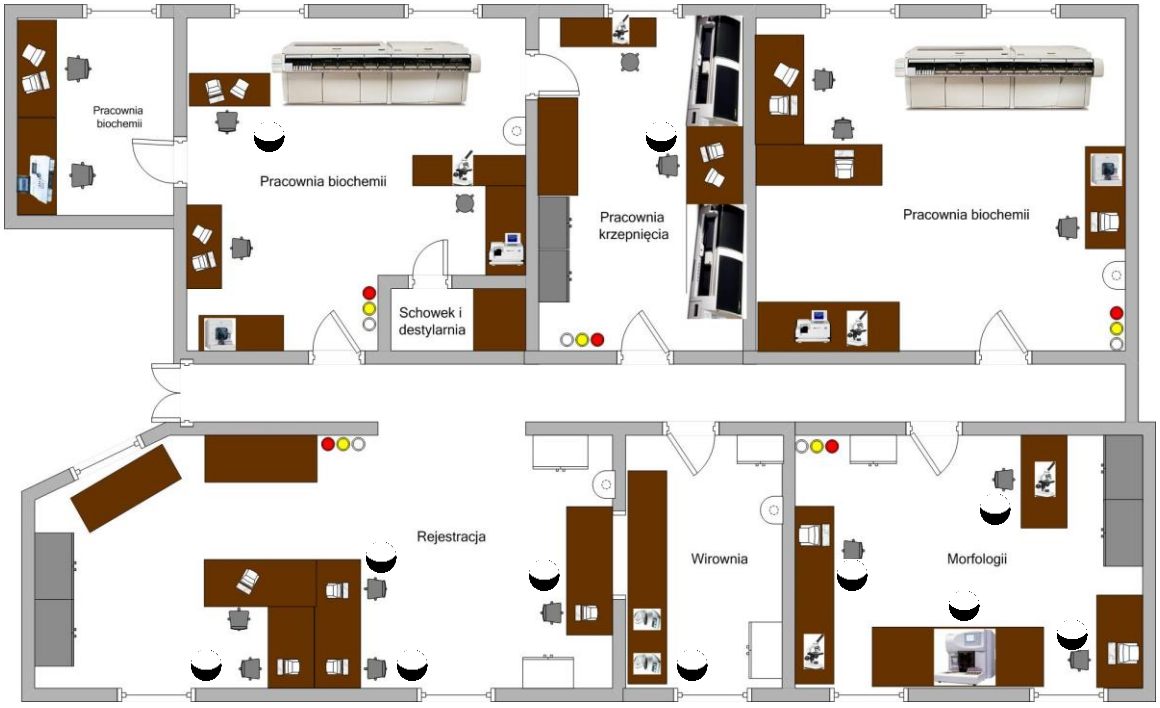
odwzorowanych w modelu. W jednym i drugim przypadku algorytmy obliczeń powinny charakteryzować się dwoma właściwościami – skończonością oraz stabilnością. W pierwszym przypadku oznacza to otrzymanie wyniku (rozwiązania) zadania w skończonym czasie. W

drugim natomiast, algorytmy powinny być konstruowane tak, aby dla tych samych danych wejściowych uzyskiwać te same rozwiązania, zaś dla różnych danych – rozwiązanie optymalne, odpowiednie do sytuacji, wynikającej z przyjętych danych wejściowych.

Weryfikacją modelu nazywamy sprawdzenie zakresu i dokładności odwzorowania w modelu właściwości obiektu, istotnych z punktu widzenia celu badań *(Smogór-Szęszoł E., 2014)*.

5. CHARAKTERYSTYKA PODMIOTU GOSPODARCZEGO

Podmiotami działalności gospodarczej mogą być jednostki i zespoły ludzkie mające zdolność organizacyjno-prawną do prowadzenia działalności gospodarczej, a więc osoby fizyczne, zespoły tworzące komórki i jednostki organizacyjne, przedsiębiorcy indywidualni, spółki osobowe i handlowe, przedsiębiorstwa państwowe, spółdzielnie itd. *(Trocki M., 2001)*. Wspólną cechą wszystkich podmiotów gospodarczych jest posiadanie podmiotowości prawnej, związanej z przypisaniem im własności i odpowiedzialności oraz ryzyka za skutki działania. Podmiot gospodarczy funkcjonujący w gospodarce określa się terminem przedsiębiorstwo. W niniejszej rozprawie rolę przedsiębiorstwa pełniło laboratorium medyczne. W laboratoriom, w którym przeprowadzono badania znajduje się 18 analizatorów (urządzeń technologicznych), które obsługuje 8 diagnostów laboratoryjnych w ciągu jednej zmiany. Te analizatory służą do oznaczenia wyników ilościowych i jakościowych badanych próbek krwi, moczu, kału, płynów z jam ciała, płynu mózgowo-rdzeniowego. Laboratorium podzielone jest na specjalistyczne pracownie biochemii, krzepnięcia, morfologii itd. Poniżej przedstawiono schematyczną wizualizację laboratorium.



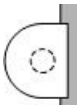
Rys. 3. Wizualizacja laboratorium medycznego.
(Źródło: opracowanie własne)

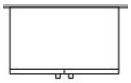
Gdzie:

 - biurka

 -krzesło

 - komputer

 -umywalka

 -lodówka

 - szafka

 -pojemniki na odpady

 -mikroskop



-wirówka

 - analizator hematologiczny XT-2000i

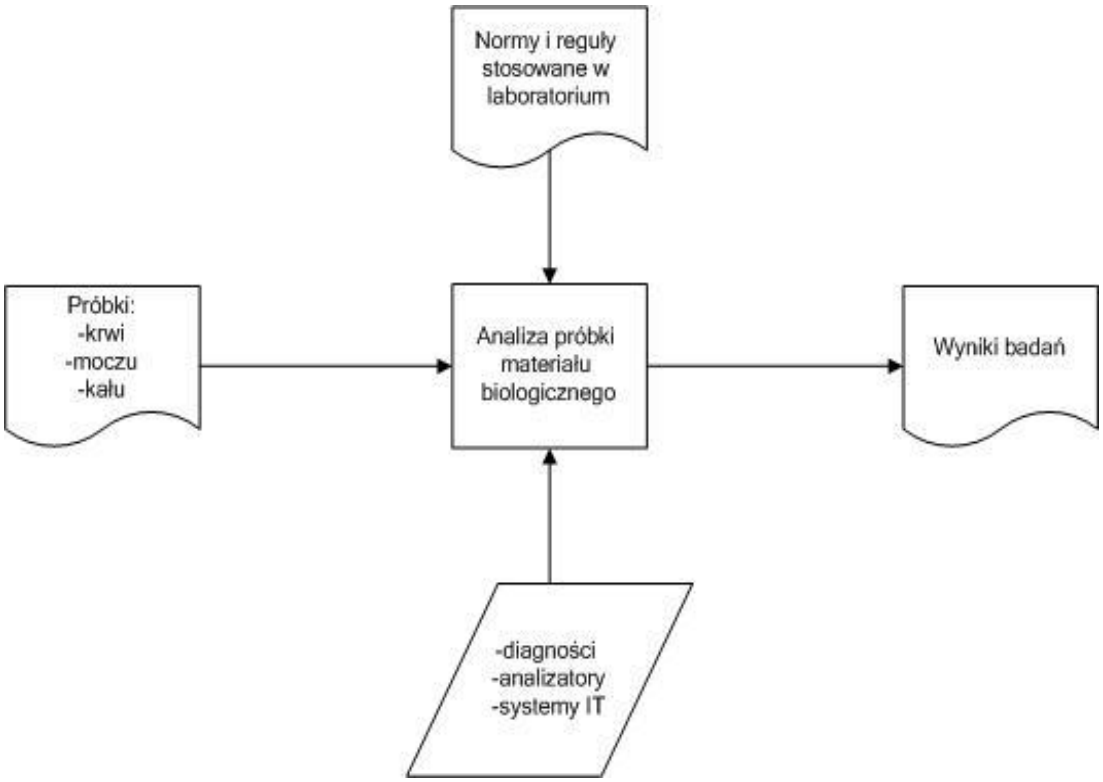
 - analizator do rutynowych oznaczeń z zakresu immunochemii Cobas e 411

 - architect ci 8200

 - cobas integra 400 plus

 - człowiek

Działalność laboratorium medycznego można opisać jako proces, który przetwarza dane wejściowe (próbki krwi itd.) w dane wyjściowe, czyli wyniki badań.



Rys. 4. Schemat przedstawiający działalność laboratorium w postaci ogólnego procesu. *(Źródło: opracowanie własne)*

W niniejszej rozprawie autor skoncentrował się na analizie przepływu materiału biologicznego przez laboratorium medyczne w całości jak również na przepływie w poszczególnych pracowniach.

6.ZASADA DZIAŁANIA PODMIOTU GOSPODARCZEGO

Analizowane laboratorium wchodzi w skład szpitalu uniwersyteckiego. Szpital uniwersytecki jest publiczną placówką służby zdrowia, udzielającą świadczenia medyczne w ramach umowy z Narodowym Funduszem Zdrowia. Celem szpitalu jest realizacja zadań badawczych i dydaktycznych w powiązaniu z udzielaniem świadczeń zdrowotnych i promocją zdrowia. Szpital stanowi bazę dydaktyczną dla studentów. Szpital Uniwersytecki jest regionalną jednostką opieki zdrowotnej oddaną poprawie stanu zdrowia mieszkańców regionu i kraju poprzez:

- kompleksowe diagnozowanie i leczenie wspierane innowacjami,
- kształcenie i wychowywanie kadry medycznej,
- prowadzenie wielozakresowych badań, służących poprawie skuteczności diagnozowania i leczenia,
- promowanie zdrowego trybu życia.

Priorytetem dla szpitalu jest realizacja projektów badawczych w powiązaniu z udzielaniem świadczeń zdrowotnych i promocją zdrowia, a misja dydaktyczna realizowana jest w oparciu o najlepszych lekarzy specjalistów oraz najnowocześniejsze metody nauczania i leczenia. Są tu hospitalizowane przypadki z medycznego punktu widzenia najtrudniejsze, wymagające wysokospecjalistycznej wiedzy i znakomitego sprzętu. Oprócz realizacji wysokospecjalistycznych procedur medycznych, jest również kształcenie przed i podyplomowe kadry medycznej, a także działalność naukowa i badawcza, która ma na celu rozwój medycyny oraz poprawę jakości leczenia *(http://jurasza.umk.pl)*.

Szpital składa się 26 oddziałów i klinik, 51 poradni i 7 zakładów. Szpital zatrudnia ponad 500 lekarzy i ponad 900 pielęgniarek. Jest to największy szpital w mieście i jeden z największych w województwie. W pracy autor skupił się na analizie jednej z jednostek wchodząca w skład szpitala. Jest to Zakład Diagnostyki Laboratoryjnej.

Zakład Diagnostyki Laboratoryjnej oferuje całodobowe świadczenia pacjentom hospitalizowanym oraz leczonym ambulatoryjnie w pełnym zakresie diagnostyki laboratoryjnej. Wszystkie badania są wykonywane w dniu ich zlecenia, z wyjątkiem badań, których procedura wykonania wymaga metod manualnych. Zakład Diagnostyki Laboratoryjnej przyjmuje materiał do badań w systemie całodobowym i wydaje wyniki tych badań po ich wykonaniu w dniu, w którym zostały zlecone. Badania laboratoryjne wykonuje się z użyciem wysokiej klasy aparatury medycznej w zakresie hematologii, chemii klinicznej, immunochemii, analityki ogólnej, toksykologii, białek specyficznych oraz alergologii *(http://jurasza.umk.pl)*.

Podstawowe kategorie badań są następujące:

- ✓ Morfologia;
- ✓ Mocz;
- ✓ Białka;
- ✓ Biochemia;
- ✓ Elektrolity;
- ✓ Układ krzepnięcia;
- ✓ Immunochemia;
- ✓ Markery nowotworowe;
- ✓ Cytochemia;
- ✓ Toksykologia;
- ✓ Inne.

W czasie przybywania w laboratorium autor pracy miał do czynienia ze 162 rodzajami badań, które należą do tych kategorii i nie powtarzają się. Zakład Diagnostyki Laboratoryjnej składa się z:

a) pracowni biochemii,
b) pracowni krzepnięcia,
c) pracowni białek,
d) pracowni morfologii,

e) rejestracji.

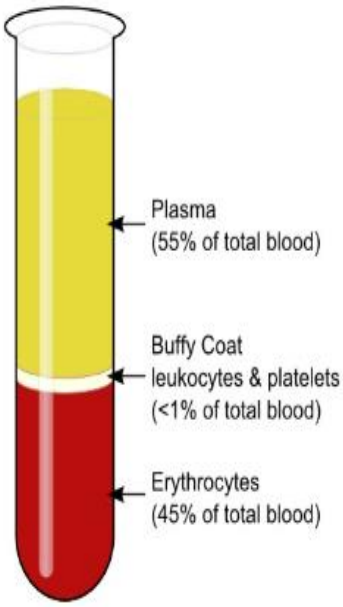
Poniżej zostaną szczegółowo opisane wymienione pracownie oraz rejestracja.

6.1 Charakterystyka procesów w wirowni

W wirowni jak sama nazwa wskazuje odbywa się proces wirowania próbek. Krew jest ciekłą tkanką, w skład której wchodzą elementy upostaciowione tj.: krwinki czerwone, krwinki białe i płytki krwi. Elementy te zawieszone są w części płynnej określanej mianem osocza lub plazmy. Osocze stanowi 55%, zaś elementy morfotyczne 45% objętości krwi. W momencie, gdy osocze zostanie pozbawione fibrynogenu, określa się je mianem surowicy krwi *(Kłyszejko-Stefanowicz L., 2003)*.

Elementy krwi mogą być oddzielone od osocza podczas kilkuminutowego wirowania w specjalnej probówce, służącej do rozdzielania składników krwi w zależności od ich gęstości. By rozdzielić elementy krwi, próbkę poddaje się wirowaniu przy 3 000 obr./minutę (bądź większych). Dochodzi do rozdzielenia faz pod wpływem działania siły odśrodkowej, w wyniku której na samej górze pozostaje osocze *(http://www.myvmc.com), (https://www.boundless.com)*.

Erytrocyty są gęstsze niż osocze, w związku z czym podczas wirowania opadają na samo dno probówki wirówkowej, stanowiąc ok. 45% całkowitej jej objętości. Leukocyty i płytki krwi tworzą tzw. kożuszek (kremowego koloru płaszcz znajdujący się tuż nad warstwą erytrocytów). Osocze (plazma) po wirowaniu występuje nas kożuszkiem w postaci jasno-żółtej warstwy, stanowiąc nieco poniżej 55% ogólnej objętości próbki *(https://www.boundless.com)*.



Rys. 5. Frakcje krwi po wirowaniu. *(Źródło:https://www.boundless.com/biology/the-circulatory-system/components-of-the-blood/plasma-and-serum/)*

Wirownia wyposażona w rejestrator oraz dwie wirówki firmy Eppendorf. Jedna wirówka zawsze pełni funkcji urządzenia zapasowego. Urządzenie ma możliwość wirowania 25 probówek w tym samym czasie. Średni czas wirowania wynosi około 10 min. Osoba odpowiedzialna za wirownię przed uzbrojeniem wirówki musi manualnie zarejestrować probówki, podobna czynność jest wykonywana po odwirowaniu probówek. Taki sposób zarządzania przepływam informacji ułatwia monitorowanie przebiegu probówki przez laboratorium.

6.2 Charakterystyka procesów w pracowni biochemii

Pracownia biochemii składa się z 3 pomieszczeń, jest to największa pracownia wchodząca w skład laboratorium. Jest to związane z tym że biochemia krwi jest jednym z najczęściej wykonywanych badań. Analiza składników osocza pozwala ocenić pracę niemal wszystkich narządów wewnętrznych człowieka. W trakcie biochemii krwi bada się osocze, które uzyskuje się poprzez odwirowanie pobranej od pacjenta krwi żylnej. W ponad 90 procentach osocze składa się z wody i rozpuszczonych w niej hormonów, enzymów, białek (albuminy, globuliny, fibrynogen), trójglicerydów, lipidów, kwasów tłuszczowych, glukozy, elektrolitów, soli

mineralnych, zbędnych produktów przemiany materii, takich jak mocznik, i bilirubina oraz wielu innych substancji. To dlatego biochemia krwi potrafi dokładnie pokazać, jak funkcjonują poszczególne układy i pracują konkretne narządy *(https://www.medme.pl).*

Dla ułatwienia analizy danych i lepszego zdiagnozowania choroby badania biochemiczne podzielono na podstawowe profile:

- profil ogólny, w którym oznacza się: sód, potas, wapń, chlorki, fosfor, kwas moczowy, mocznik, kreatyninę, bilirubinę, AspAT, ALT, fosfatazę alkaliczną, GGT, albuminę, białko całkowite
- profil wątrobowy, w którym oznacza się: transaminazę alaninową asparaginianową (ALT i AspAT)
- profil nerkowy, w którym oznacza się: sód, potas, mocznik, kreatyninę
- profil sercowy, w którym oznacza się: transaminazę alaninową (ALT) i asparaginową (AspAT), kinazę kreatynową (CK), dehydrogenazę mleczanową (LDH), potas
- profil tarczycowy, w którym oznacza się: hormony TSH i T4
- profil lipidowy, w którym oznacza się: cholesterol, trójglicerydy (TG), cholesterol HDL, cholesterol LDL
- profil kostny, w którym oznacza się: białko całkowite, albuminę, wapń, fosfor, fosfatazę alkaliczną

Można też wykonać bardziej szczegółowe profile, np. profil alergiczny, reumatyczny, profil dla ciężarnych itd.

Najmniejsze pomieszczenie pracowni biochemii służy do wykonywania rozmazów manualnych. Jest to czasochłonny proces, w którym na stałe jest zaangażowany jeden diagnosta laboratoryjny. Dwa kolejne pomieszczenia są identyczne. Są wyposażone w podobne urządzenia. Jest to spowodowane zabezpieczeniem laboratorium przed możliwymi awariami maszyn (analizatorów). Laboratorium nie może pozwolić sobie na przestój z powodu awarii, dlatego urządzenia są zdublowane. Urządzenia w tych pomieszczeniach są używane zamienne co tydzień. Taki sposób

zarządzania analizatorami w pracowni biochemii pomaga administratorowi posiadać pełną informację o stanie wszystkich urządzeń jak również odczynników wykorzystywanych do badań.

Pracownia biochemii jest wyposażona w dwa analizatory immunochemiczne Architect i2000 SR. Analizator posiada podajnik na 135 próbek i wykonuje 200 oznaczeń na godzinę. Analizator obsługuję jeden diagnosta laboratoryjny. Do obowiązków tej osoby należy dostarczenie próbek z wirowni, umieścić próbki w analizatorze, sprawdzać i zatwierdzać wyniki badań, które generuje analizator. Warto zauważyć, że z jednej probówki krwi są wykonywane różne oznaczenia. Aby informacja na bieżąco spływała do klinik diagnosta musi prawie na stałe być przy pulpicie sterującym i zatwierdzać wyniki.

6.3 Charakterystyka procesów w pracowni krzepnięcia

Głównym celem badań wykonywanych w pracowni krzepnięcia jest ocena funkcji układu krzepnięcia krwi oraz ocena stopnia reaktywności płytek krwi. Wykonanie badań zmniejsza ryzyko powikłań krwotocznych i zakrzepowo-zatorowych po operacjach kardiochirurgicznych oraz sprzyja zwiększeniu bezpieczeństwa i skuteczności wielomiesięcznej profilaktyki przeciwpłytkowej po przezskórnych interwencjach wieńcowych i zastawkowych. Badania pozwalają na celowane leczenie w przypadku powikłań krwotocznych po zabiegach kardiochirurgicznych oraz dobranie optymalnej profilaktyki przeciwpłytkowej po przezskórnych interwencjach wieńcowych *(https://www.klinikiserca.pl)*.

Pracownia krzepnięcia składa się z jednego pomieszczenia. Pracownia wyposażona jest w dwa analizatory Roche Cobas INTEGRA 400 Plus. Podobnie jak w pracowni biochemii zdublowanie urządzeń wynika z braku możliwości powstawania przestojów w laboratorium. Wydajność analizatora wynosi 340 oznaczeń na godzinę (*https://www.medipment.pl)*. Pracownia wyposażona jest również w stanowisko do zatwierdzania rezultatów oraz stanowisko do oznaczeń manualnych które są wykonywane w przypadkach, kiedy analizator wydaje nietypowy wynik. Podobnie jak w przypadku z pracownią biochemii, aby informacja na bieżąco spływała do

klinik diagnosta musi prawie na stałe być przy pulpicie sterującym i zatwierdzać wyniki.

6.4 Charakterystyka procesów w pracowni morfologii

Morfologia krwi to jedno z podstawowych i najczęściej wykonywanych badań diagnostycznych. Dzięki niemu można określić ogólny stan zdrowia badanego, wykryć ewentualne zakażenia i inne stany chorobowe. Badanie jest proste i polega na pobraniu niewielkiej ilości krwi (najczęściej z żyły w zgięciu łokcia, lub opuszka palca).

Morfologia krwi obwodowej jest badaniem, dzięki któremu można ocenić najważniejsze parametry dotyczące elementów morfotycznych krwi, czyli erytrocytów (czerwonych krwinek), leukocytów (białych krwinek) i trombocytów (płytek krwi) *(http://www.cmkarpacz.pl)*.

W pracowni morfologii są oznaczane:

- WBC - krwinki białe, czyli leukocyty;
- RBC - czerwone krwinki, czyli erytrocyty;
- HGB – hemoglobina;
- MCV - średnia objętość czerwonej krwinki;
- RDW - rozkład objętości krwinek czerwonych;
- HCT – hematokryt;
- MCH - średnia masa hemoglobiny w krwince;
- MCHC - średnie stężenie hemoglobiny w krwince;
- PLT - płytki krwi, czyli trombocyty;
- LYMPH %- limfocyty (odsetek procentowy);
- EOS% - eozynofile, czyli leukocyty kwasochłonne (odsetek procentowy);

- BASO% - bazofile, czyli leukocyty zasadochłonne (odsetek procentowy);
- NEUT% - neutrofile, czyli leukocyty obojętnochłonne (odsetek procentowy);
- MONO %- monocyty (odsetek procentowy);
- LYMPH #- limfocyty (liczba bezwzględna limfocytów);
- EOS#- eozynofile, czyli leukocyty kwasochłonne (liczba bezwzględna eozynofili);
- BASO# - bazofile, czyli leukocyty zasadochłonne (liczba bezwzględna bazofili);
- NEUT# - neutrofile, czyli leukocyty obojętnochłonne (liczba bezwzględna neutrofili);
- MONO#- monocyty (liczba bezwzględna monocytów).

Pracownia morfologiczna składa się z jednego pomieszczenia, które jest wyposażone w dwa stanowiska do manualnego oznaczania, automatyczny analizator DIAGON oraz trzy stanowiska do zatwierdzania i wprowadzania danych do systemu *(https://www.medipment.pl)*. Analizator w pracowni morfologii jest tylko jeden i w przypadku awarii wszystkie badania są wykonywane manualnie jak również wszystkie dane są wprowadzane do systemu manualnie a następnie zatwierdzane. Do pracowni morfologii są przypisane cztery osoby.

6.5 Charakterystyka procesów zachodzących w rejestracji

O godzinie 7:00 pracę zaczyna większość diagnostów laboratoryjnych (6 osób) dla tego można stwierdzić, że właśnie wtedy zaczyna pracować laboratorium (podczas dyżurów jest wykonywana mała ilość badań, najczęściej są to badania pilne które nie mogą czekać do jutra). W pierwszej kolejności są rejestrowani pacjenci z intensywnej terapii, klinik dziecięcych, różnego rodzaju chirurgii i kardiologii.

Próbki u pacjentów mogą być pobrane nawet o godzinie 5:50. Jeżeli nie są to pilne badania to wtedy te probówki czekają na rozpoczęcie pracy laboratorium. Probówki z klinik już są przenoszone do laboratorium z naklejonymi kodami kreskowymi i blankami z odpowiednimi kodami kreskowymi, na których są wypisane potrzebne badania. W ten sposób minimalizuje się ryzyko pomylenia próbek pacjentów w trakcie przetransportowania biomateriału z kliniki do laboratorium.

Kod kreskowy jest przydzielany pacjentowi i próbkom. Kod, który się kończy 0 jest naklejany na blank ze spisem badań, cyferki 1,2,3 są przeznaczone do próbek z niebieskim, czerwonym i fioletowym korkiem.

1) Etap przyjmowania próbek i blanków:

Na każdym blanku osoba przyjmująca musi napisać godzinę przyjęcia, następnie próbki trafiają na stanowisko nr1 lub nr2.

2) Etap rejestracji pacjenta:

Przy stoliku nr1 i nr2 są rejestrowani pacjenci. Na początku skanuje się kod kreskowy, następnie do systemu wpisuje się nazwisko i imię tego pacjenta, numer pesel, jeżeli ten pacjent trafił do tego szpitala pierwszy raz, oraz imię i nazwisko lekarza.

3) Etap wprowadzenia badań z listy:

Pojawia się tabela z badaniami, kliknięciem wybiera się badania potrzebne poszczególnemu pacjentowi. To jest ostatni etap. Teraz kod kreskowy niesie w sobie informację związaną z rodzajem i ilością badań oraz badaną osobą. Dodatkowo każdy pacjent ma swój numer porządkowy który otrzymuje przy rejestracji. Te numery są przeznaczane po kolei.

Osoba przy stanowisku nr3 sprawdza w systemie czy do poszczególnych badań są wszystkie potrzebne probówki i w razie błędu sprawdza się blank, a jeżeli te badania są wymienione w blanku a nie ma do tego probówki, to wtedy się dzwoni do kliniki, do której jest przypisany pacjent z prośbą o uzupełnienie materiału biologicznego.

Rodzaje próbek:

- Mocz;

- Czerwony korek – skrzep;
- Niebieski korek – układ krzepnięcia;
- Różowy korek – morfologia.

W poszczególnych pracowniach wyniki badań są zatwierdzane online jednak w szpitalu obowiązuje również dokumentacja papierowa. Dla tego wszystkie wyniki są drukowane i zatwierdzane przez diagnostę laboratoryjnego w rejestracji. Przed zatwierdzeniem wyników diagnosta weryfikuje wyniki co pozwala na zminimalizowanie możliwości powstania błędu. Jest to czwarta osoba pracująca w rejestracji.

6.6 Charakterystyka i analiza przepływu danych w poszczególnych pracowniach.

Pracownie biochemii, krzepnięcia oraz morfologii wykonują różne badania jednak czynności, które musza wykonywać analitycy medyczni są wspólne. Zadaniem każdego pracownika jest wykonanie badań w najszybszym czasie, jednak każda z pracowni jest uzależniona od rejestracji i wirowni. Taki sposób organizacji powoduje przestoje lub kolejkowanie się probówek w pracowniach. Wprowadzenie rytmiczności pracy zdaniem autora ułatwi wykonywanie zadań i zmniejszy ryzyko powstania błędu.

Ze względu na dużą odpowiedzialność pracy wykonywanej przez analityków system zarządzania laboratorium jest wspomagany systemem komputerowym który monitoruje etapy zatwierdzania probówek i badań. Etapowe zatwierdzenia wymagają dużego zaangażowania pracowników. Na przykładzie osoby odpowiedzialnej za obszar wirowni można zauważyć minusy systemu zatwierdzania. Analityk musi przed włożeniem probówek do wirówki dokonać rejestracji 25 próbek, następnie ma 10 minut, żeby zarejestrować odwirowane probówki i kiedy dokona tych czynności musi znowu zabierać się za kolejne rejestrowanie. W systemie pojawia się informacja, że odwirowane próbki czekają na badania, analityk odpowiedzialny za dedykowaną pracownię musi odebrać probówki w wirowni i zanieść na pracownię. Może to być 20 probówek a czasami tyko 2 probówki. Jest to nieracjonalne wykorzystanie pracownika, który musi chodzić za każdym razem nie zwracając uwagi na ilość oczekujących probówek. Wirownia nie ma wpływu na rodzaj próbek, które trafiają do

odwirowania, bo próbki przekazuje rejestracja. Rejestracja również nie ma wpływu na zlecane do wirowania probówki, bo jest uzależniona od klinik zlecających badania. W pracy autor skupił się na stworzeniu algorytmu harmonogramowania procesów który pozwoli na przewidywanie obciążeń w kolejnym dniu co pozwoli na grupowanie badań i pozwoli na zwiększenie rytmiczności pracy.

7.ZASADA DZIAŁANIA BIG DATA

W związku z narastającym gwałtownie zainteresowaniem Big Data wielu naukowców i firm z branży IT podjęło próby rozpoznania i opisania tego terminu. Charakterystyka i definicje przez lata ewoluowały. Interpretując Big Data, należy się odnieść do nowych rozwiązań technologicznych dotyczących przetwarzania wielkich wolumenów danych o całkowicie innym charakterze (ilościowym i jakościowym) niż dotychczas (*McKinsey , 2011)*. Poniżej zaprezentowane zostały wybrane definicje oraz propozycja definicji wraz atrybutami, które charakteryzują Big Data. Przedstawiono wyzwania badawcze i technologiczne, m.in. istotność informacji, objętość danych, integracja danych, wnioskowanie.

Poniżej przedstawiono kilka popularnych definicji Big Data. Jedna z pierwszych definicji Big Data została wprowadzona przez M. Cox i D. Ellsworth *(Cox M., 1997)*. Autorzy traktują Big Data jako duże dane do analizowania, których liczbę należy maksymalizować w celu wydobycia wartości informacyjnych.

Inną propozycję definicji wysunął analityk pracujący dla firmy Gartner w 2001 r., ówcześnie META Group (firmy analityczno-doradczej specjalizującej się w technologiach informacyjnych). Oparł ją na koncepcji trzech atrybutów w modelu „3V”. Big Data charakteryzują atrybuty: objętość (ang. volume), różnorodność (ang. variety), szybkość przetwarzania (ang. velocity) (*Doug L.,2001)*. Następnie w roku 2012 firma Gartner [www.gartner.com] wprowadziła dodatkowe dwa wymiary odnoszące się do dużych danych: zmienność (ang. variability) i złożoność (ang. complexity).

Big Data to duża liczba danych, która wymaga zastosowania nowych technologii i architektur, tak by była możliwa ekstrakcja wartości płynącej z tych danych poprzez uchwycenie i analizę procesu, to sentencja, jaką przedstawiają autorzy publikacji *(Katal A., 2013)*.

Kolejną definicję Big Data prezentują Fan i Bifet *(Fan W., 2012)*, opisując w niej Big Data jako termin oznaczający zbiory danych, którymi nie można zarządzać za pomocą obecnych metod eksploracji lub narzędzi programowych ze względu na duży rozmiar i złożoność danych.

IBM w 2013 r. definiuje Big Data jako różnorodne dane generowane z różnych źródeł, z dużą prędkością oraz w dużej ilości. IBM charakteryzuje Big Data za pomocą czterech atrybutów: objętość (ang. volume), szybkość przetwarzania (ang. velocity), różnorodność (ang. variety) oraz wiarygodność (ang. veracity) *(www.ibm.com)*.

SAS *(www.sas.com)* definiuje Big Data jako tendencje do poszukiwania i wykorzystania wartości biznesowej drzemiącej w dostępnych, coraz większych wolumenach danych, które charakteryzują się dużą zmiennością i złożonością. SAS opisując Big Data, zwraca uwagę na dodatkowe dwa atrybuty: zmienność (ang. variability) oraz złożoność (ang. complexity).

Na podstawie analizy definicji pojęcia Big Data można zauważyć, iż żadna z nich nie odzwierciedla w pełni tej problematyki. Nie można też wskazać na konkretną ilość bajtów, od których można mówić o dużych ilościach danych, gdyż tempo ich przyrostu jest zbyt wielkie *(Cisco, 2012)*. W związku z tym poniżej przedstawiona została inna propozycja definicji Big Data.

Big Data to określenie stosowane dla takich zbiorów danych, które jednocześnie charakteryzują się dużą objętością, różnorodnością, strumieniowym napływem w czasie rzeczywistym, zmiennością, złożonością, jak również wymagają zastosowania innowacyjnych technologii, narzędzi i metod informatycznych w celu wydobycia z nich nowej i użytecznej wiedzy *(Tabakow M., 2014)*.

Termin Big Data charakteryzowany jest przede wszystkim kilkoma kluczowymi atrybutami, takimi jak: objętość (ang. volume), różnorodność (ang. variety), złożoność (ang. complexity), strumień (ang. velocity),

zmienność (ang. variability) i wartość (ang. value). Big Data należy rozumieć jako techniki łączące rozwiązania z poniższych obszarów charakteryzujących dane. Poniżej przedstawiono definicje cech Big Data.

- *Objętość* charakteryzuje się znaczącą dynamiką przyrostu danych, dla których wymagane są nowe technologie bazodanowe. Badania wskazują, że liczba danych do 2020 r. wzrośnie o 40% zettabajtów (zettabajt skrót ZB jest jednostką używana w informatyce oznaczającą odpowiednio 1000^7 bajtów), co oznacza 50-krotny wzrost od początku 2010 r.

- *Szybkość* – dane napływające szybko, strumieniowo, które w związku z procesami biznesowymi wymagają dodatkowej mocy obliczeniowej do ich analizy w czasie rzeczywistym. Dane, które w związku z ograniczoną przepustowością sieci należy pobierać porcjami i wybierać tylko te, które mają istotną wartość informacyjną czy biznesową z punktu widzenia danej organizacji.

- *Różnorodność* – dane pochodzą z wielu źródeł i często występują w różnych formatach i są zapisywane za pomocą różnych modeli oraz wyrażane w dowolnej formie, np.: liczbowo, tekstowo, obrazowo, dźwiękowo, oraz generowane w różny sposób.

- *Zmienność* – dane, których natężenie jest zmienne w czasie, a przepływy danych podlegają okresowym cyklom i trendom, a także szczytom, co związane jest również z dynamiką procesów i zmian gospodarczych czy politycznych. Przykładem może być sprzedaż produktów i usług w okresie Bożego Narodzenia, wzmożona aktywność w mediach społecznościowych towarzysząca wyborom parlamentarnym, nagłe „ruchy" na giełdzie czy okresowa rotacja portfeli inwestycyjnych.

- *Złożoność* – złożoność danych jest ściśle związana z różnorodnością. Charakteryzuje się różnym uporządkowaniem danych. Są to m.in. dane o określonej strukturze, mające określony typ i format, dane o mieszanej strukturze, częściowo uporządkowane (semi-struktured, „quazi" structured), posiadające pewne właściwości organizacyjne, oraz dane niemające naturalnej struktury (unstructured), które należy zintegrować w celu odkrycia nieznanych relacji, powiązań i

hierarchii. Do danych strukturalnych należą: numery telefonów, pesel, numer karty kredytowej – zawsze zawierają one zdefiniowaną liczbę pól. Dane o mieszanej strukturze to np. pliki XML, e-mail, Elektroniczna Wymiana Danych (Electronic Data Interchange, EDI). Natomiast dane niestrukturalne to: dokumenty, pliki wideo i zdjęcia. Ekstrakcja informacji z tych surowych treści oraz odpowiednio dobrane do nich metody są niezbędne do dalszego przetwarzania informacji przez algorytmy analizy *(Chang C., 2006)*.

- *Wartość* – unikatowa wartość informacyjna ukryta w dużych i złożonych strukturach danych, dająca możliwość wyciągania nowych wniosków, które następnie przyczyniają się do wzrostu efektywności działania organizacji na różnych płaszczyznach. Można wskazać niektóre elementy działalności przedsiębiorstwa, na które ma wpływ wykorzystanie wartości, jakie niesie Big Data: efektywniejszy wewnętrzny model biznesowy, model doboru kadr, spersonalizowana oferta dla klientów, strategia marketingowa i konkurencyjna. Dodatkowo można zauważyć kolejną zaletę związaną ze stosowaniem Big Data w organizacji: dzięki Big Data można odpowiedzieć niemal natychmiast na stawiane pytania czy zdefiniowane problemy biznesowe. Wartość jest istotnym atrybutem Big Data. Może być rozumiana jako unikalna wiedza z naukowego punktu widzenia, jak i wartość informacyjna będąca korzyścią biznesową, mającą wpływ na obniżenie kosztów działalności organizacji czy na poprawę relacji biznesowych i zysków *(Tabakow M., 2014)*.

Wyzwania badawcze wynikają z charakterystyki Big Data. Związane są z ilością danych, z ich złożonością, różnorodnością oraz liczbą źródeł informacji. Wyzwania badawcze można podzielić na technologiczne i praktyczne związane z powstawaniem danych. Wyzwania technologiczne to przede wszystkim opracowanie innowacyjnej architektury, przy czym architekturę rozumie się jako szkielet dla całego procesu związanego z wykorzystywaniem danych, począwszy od wyznaczenia źródeł danych, które są interesujące z punktu widzenia biznesowego, poprzez ich pobieranie, gromadzenie, wstępne przetwarzanie, rozdzielanie, analizę, modelowanie do wnioskowania. Obecnie Big Data to „nowe" dane z

różnych źródeł. Potrzebna jest zatem identyfikacja istotnych źródeł danych. Nasuwają się więc pytania: Z jakich źródeł czerpać dane? Jakie źródła będą istotne dla realizacji celów biznesowych? Jak identyfikować te źródła? Czy można je identyfikować automatycznie i czy te narzędzia będą personalizowane? Narzędzia takie powinny być częścią architektury przeznaczonej do zarządzania Big Data. Identyfikacja istotnych informacji to ważny aspekt zarządzania danymi Big Data. Istnieje konieczność określenia filtrów danych, by z jednej strony nie pobierać nadmiernych, niepotrzebnych danych i nie generować zbędnych kosztów, a z drugiej strony, by nie pominąć tych istotnych. Ponadto wielkim wyzwaniem jest automatyczne generowanie metadanych, opisujących dane *(Tabakow M., 2014)*.

7.1 Tensor, zastosowanie w Big Data

Fundamentem każdej tensorowej metody reprezentacji danych jest założenie, że dane wejściowe to zbiór n-atrybutowych krotek, przy czym każdej krotce przypisana jest wartość (interpretowana jako prawdopodobieństwo, wartość logiczna, itp.).

Sposób reprezentacji zbioru krotek w przestrzeni tensorowej można zdefiniować jako:

$$\Gamma = (n, V^{(1)}, ..., V^{(n)}, \Lambda, \psi). \quad (1)$$

Gdzie:

- Γ to funkcja gamma (zwana też gammą Eulera) – funkcja specjalna, która rozszerza pojęcie silni na zbiór liczb rzeczywistych i zespolonych.
- $V^{(i)}, (i = 1, ..., n)$ to zbiór możliwych wartości tego atrybutu n-atrybutowej krotki,
- Λ to zbiór krotek postaci $(v^{(1)}, ..., v^{(n)})$, takich, że $v^{(i)} \in V^{(i)}$

- $\psi : V^{(1)},...,V^{(n)} \rightarrow R$ to funkcja przypisująca wartości poszczególnym krotkom ze zbioru Λ .

W celu wyrażenia dowolnego zbioru n-atrybutowych krotek w postaci tensora, określa się przestrzeń tensorową $T = I^{(1)} \otimes ... \otimes I^{(n)}$, przy czym $I^{(i)}$ to baza przestrzeni rzędu $\left|V^{(i)}\right| = n_i$ służąca indeksowaniu elementów ze zbioru $V^{(i)}$.

Dowolny zbiór n-atrybutowych krotek (w tym pojedyncza krotka), może być wyrażony jako punkt w przestrzeni tensorowej T *(Szwabe A., 2016)*.

Zastosowanie metod tensorowych w Big Data wymagają uniwersalizacji reprezentacji danych wejściowych, przy zachowaniu:

- Ścisłej interpretowalności modelu danych *(Matwin S., 2013)*
- Możliwości weryfikacji zestawów cech opisujących zjawisko w celu znalezienia cech kooperujących z perspektywy wyniku klasyfikacji *(Draminski M., 2016)*

Każdy model oparty na iloczynie tenserowym daje naturalna możliwość reprezentacji każdego wyrażalnego w systemie zdarzenia (próbki/krotki) jako iloczynu logicznego → tensorowego) współwystępowania wartości atrybutów określających to zdarzenie.

Proponowany model - jako oparty na hierarchicznej sieci tensorów (połączonych relacjami kontrakcji wymiarów indeksowania) - daje mozliwość:

- weryfikacji wszystkich sposobów uogólnienia (uproszczenia) modelu w alternatywny sposób determinujących wyrażalność poszczególnych koniunkcji atrybutów,
- integracji wyników przetwarzania uzyskanych dla wszystkich alternatywnych sposobów uogólnienia modelu *(Szwabe A., 2016)*.

Metody tensorowe od kilku lat uznawane są za skuteczne narzędzie analizy danych wielorelacyjnych; do najpopularniejszych należą metody oparte na

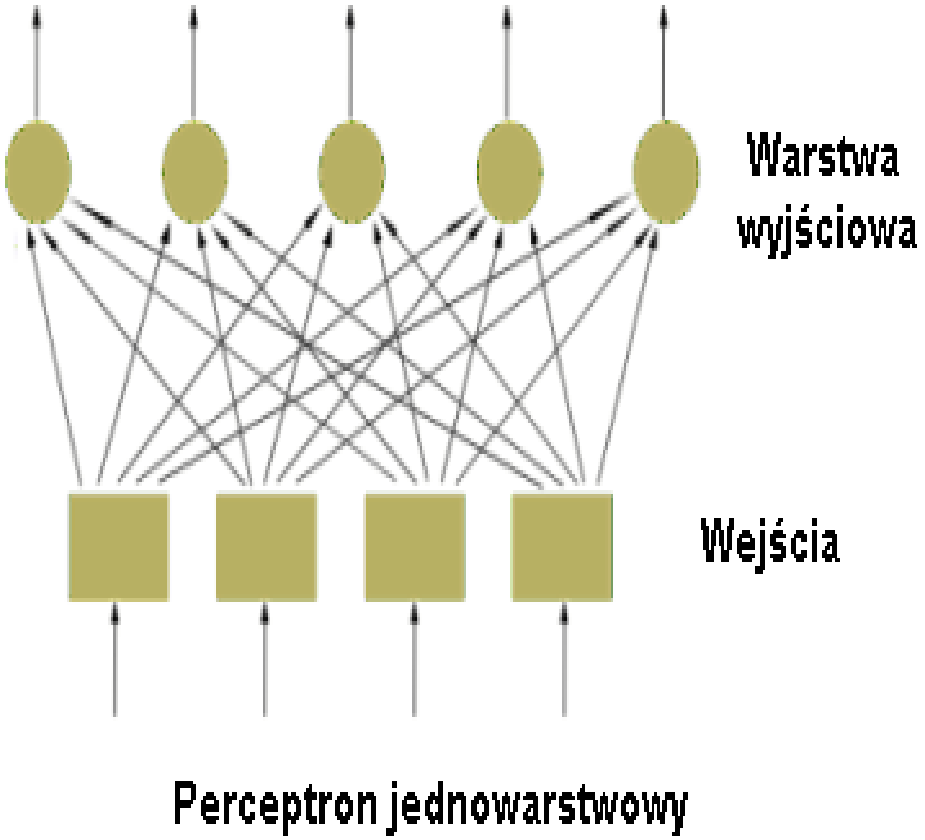
redukcji wymiarowości zużyciem metod dekompozycji *(Kolda, T. G., 2009)* oraz iteracyjnej ortogonalizacji (algorytm Higher-Order Orthogonal Iteration) *(de Lathauwer L.,2000)*.

Jako narzędzie, które pozwoli zobrazować tensorową metodę reprezentacji danych autor zastosował sieci neuronowe. W niniejszej pracy sieć neuronowa pełni funkcje narzędzia, które ułatwia wykonywanie obliczeń, symulacji oraz generowanie wykresów.

7.2 Sieci neuronowe

Pierwowzorem sieci neuronowych jest mózg ludzki który składa się z 1010 komórek nerwowych między którymi jest 1015 połączeń. Komórki nerwowe przetwarzają impulsy z częstotliwością 1 - 100 Hz. Daje to przybliżoną prędkość pracy mózgu: 1018 operacji na sekundę, co wielokrotnie przewyższa możliwości obecnych superkomputerów. Sieć neuronowa jest bardzo uproszczonym modelem mózgu. Składa się ona z dużej liczby elementów przetwarzających informację zwanych neuronami. Połączone są one ze sobą w pewien określony sposób.

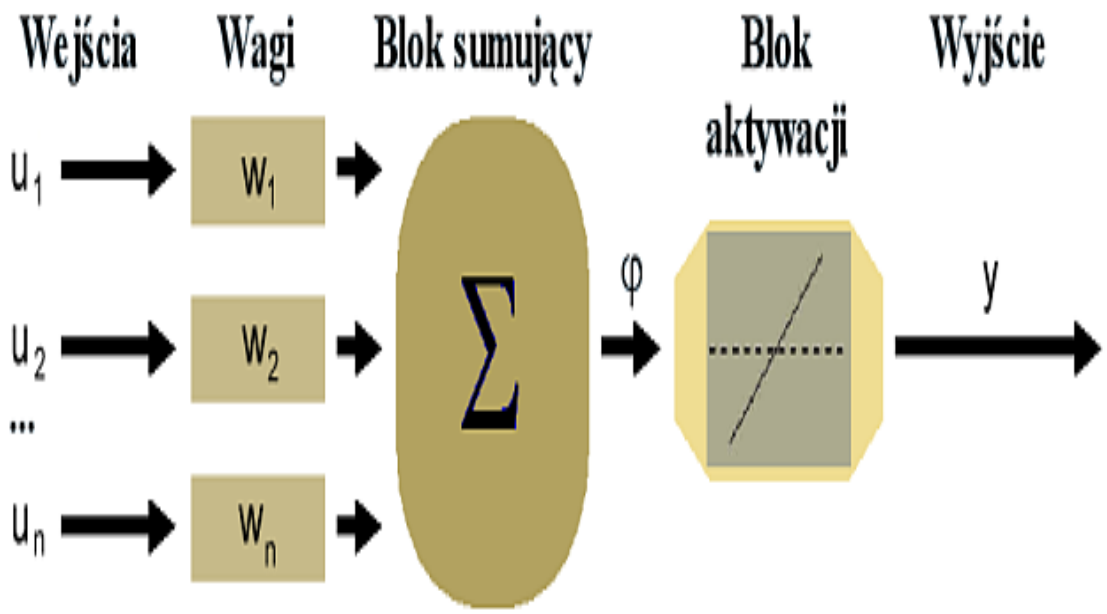
Początki sztucznej inteligencji sięgają lat czterdziestych ubiegłego stulecia, kiedy to opracowano model neuronu w mózgu ludzkim i zwierzęcym (McCulloch i Pitts, 1943) oraz wyjaśniono mechanizm zapamiętywania informacji przez sieć biologiczną. Dalszy rozwój tej nauki zaowocował zaprojektowaniem i zbudowaniem przez Rosenblatta (1958) sztucznej sieci neuronowej zwanej perceptronem. Był to elementarny system wizualny, który mógł być nauczony rozpoznawania ograniczonej klasy wzorów. W tych latach próbowano też pierwszych zastosowań komputerów między innymi do przewidywania pogody, identyfikacji formuł matematycznych, czy analizy elektrokardiogramu.



Rys.6. Schemat sztucznej sieci neuronowej zwanej perceptronem.
(Źródło:http://galaxy.uci.agh.edu.pl/~vlsi/AI/wstep/)

Po publikacji w 1969 książki Minsky'ego i Paperta, w której udowodnili, że jednowarstwowe sieci mają skończone zastosowania, nastąpił odwrót od sieci neuronowych w kierunku systemów ekspertowych. Powrót zainteresowania w połowie lat osiemdziesiątych zapoczątkowały prace ukazujące, że wielowarstwowe, nieliniowe sieci neuronowe nie mają ograniczeń. W tym też okresie rozpoczął sie rozwój neurokomputerów, na który także miał wpływ postęp technologii wytwarzania układów scalonych VLSI. Ważnym osiągnięciem są także różnego rodzaju metody uczenia sieci wielowarstwowych np. algorytm wstecznej propagacji błędów *(Tadeusiewcz R., 1992)*.

Na podstawie działania neuronu biologicznego można zbudować schemat działania neuronu sztucznego. Składa się on z wielu wejść z których sygnały są sumowane z odpowiednimi wagami a następnie poddawane działaniu funkcji aktywacji *(Korbicz J., 1994), (Haykin S., 1999)*:



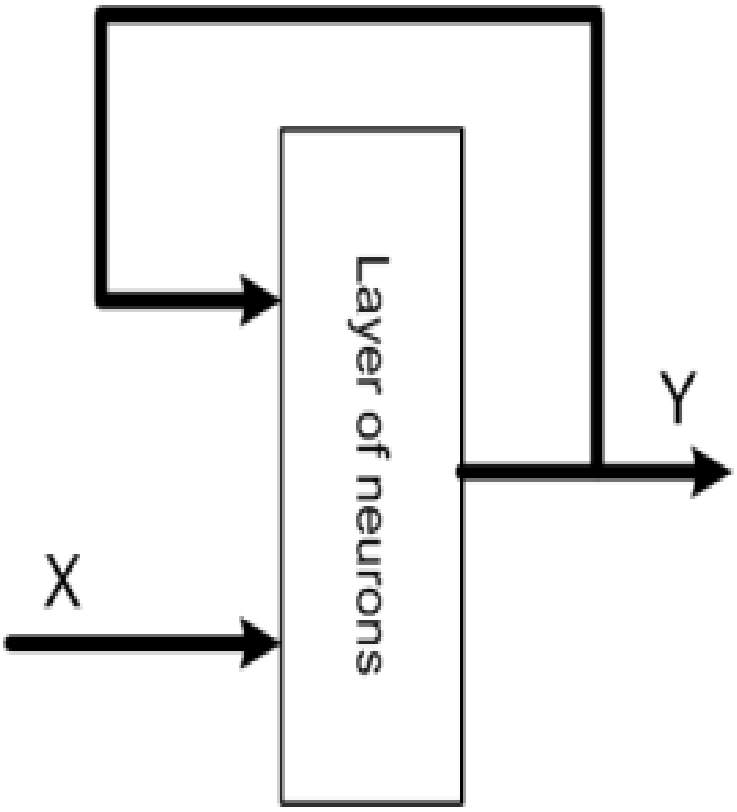
Rys. 7. Model neuronu. *(Źródło: http://galaxy.uci.agh.edu.pl/~vlsi/AI/wstep/)*

Rodzaj sieci neuronowej zależy od sposobu połączenia neuronów tej sieci oraz od kierunku przepływu sygnałów w sieci. Każdy typ sieci ma własne metody doboru wag, czyli uczenia. Istnieje bardzo wiele rodzajów sieci neuronowych jednak najbardziej podstawowe, obrazujące budowę i sposób działania to:

- sieci jednokierunkowe,
  - jednowarstwowe,
  - wielowarstwowe,
- sieci rekurencyjne,
- sieci komórkowe.

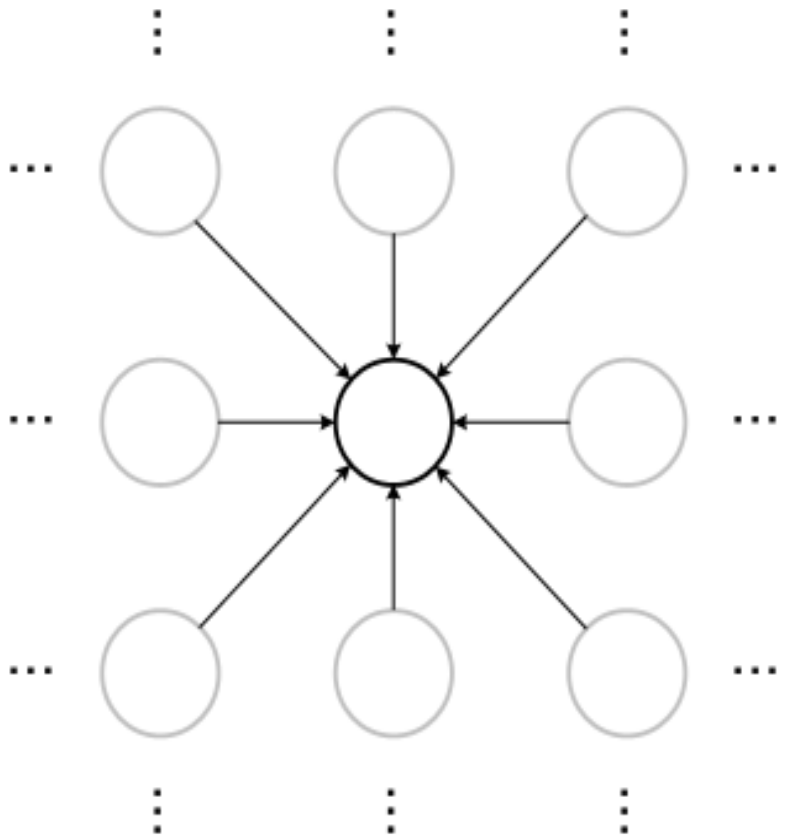
Sieci jednokierunkowe których typowym przykładem jest perceptron jednowarstwowy (rys. perceptronu) składają się z neuronów ułożonych w warstwach o jednym kierunku przepływu sygnałów i połączeniach międzywarstwowych jedynie między kolejnymi warstwami. Sieć tego typu posiada warstwę wejściową, wyjściową i warstwy ukryte. Z funkcjonalnego punktu widzenia układ taki można traktować jako układ aproksymacji funkcji nieliniowej wielu zmiennych $y = f(u)$

Sieci rekurencyjne W sieciach tego typu występuje przynajmniej jedno sprzężenie zwrotne. Oznacza to, że sygnały wyjściowe warstwy podawane są na jej wejścia, co powoduje pewną dynamikę w pracy sieci. Sygnały wejściowe w takiej sieci zależą zarówno od aktualnego stanu wejścia jak i od sygnałów wyjściowych w poprzednim cyklu. Strukturę ogólną takiej sieci przedstawia poniższy rysunek.



Rys. 8. Struktura ogólna sieci rekurencyjnej.
(Źródło:http://galaxy.uci.agh.edu.pl/~vlsi/AI/wstep/)

Sieci komórkowe W tych sieciach sprzężenia wzajemne między elementami przetwarzającymi dotycza jedynie najbliższego sąsiedztwa. Połączenia te są w ogólności nieliniowe i opisane poprzez układ równań różniczkowych. Podstawową trudność w stosowaniu tego typu sieci stanowi opracowanie skutecznej, efektywnej i uniwersalnej metody projektowania. Typowym przykładem sieci komórkowej może być sieć typu mapa Kohonena *(Kos A., 2004), (Sanocki Ł., 2005)*.



Rys. 9. Sieć typu mapa Kohonena. *(Źródło: http://galaxy.uci.agh.edu.pl/~vlsi/AI/wstep/)*

W pracy zastosowano sieci rekurencyjne które pozwalają wykorzystać sygnały wejściowe zarówno od aktualnego stanu wejścia jak i od sygnałów wyjściowych w poprzednim cyklu. Czyli sieć analizuje dane uzyskane w laboratorium z jednego dnia i porównuje go z poprzednim dniem, tym samym nadaje nowe zależności i szuka nowych powiązań.

8.PROCEDURA BADAŃ

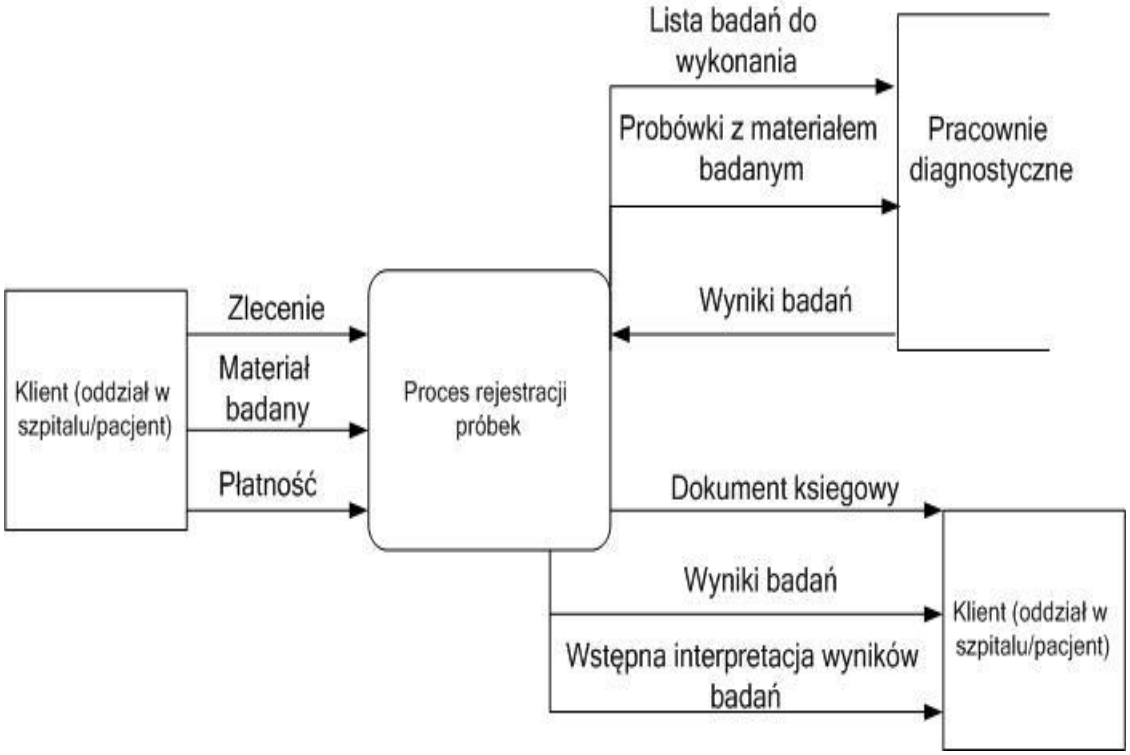
8.1 Analiza danych diagramem przepływu danych

Jedną z metod wykorzystywanych na etapie analizy służących do modelowania funkcji systemu jest Diagram Przepływu Danych (ang. Data Flow Diagram - DFD). Przedstawia on, w jaki sposób dane przepływają w

systemie oraz opisuje procesy przetwarzające dane. Tworzenie diagramu DFD opiera się na następujących kategoriach pojęciowych:

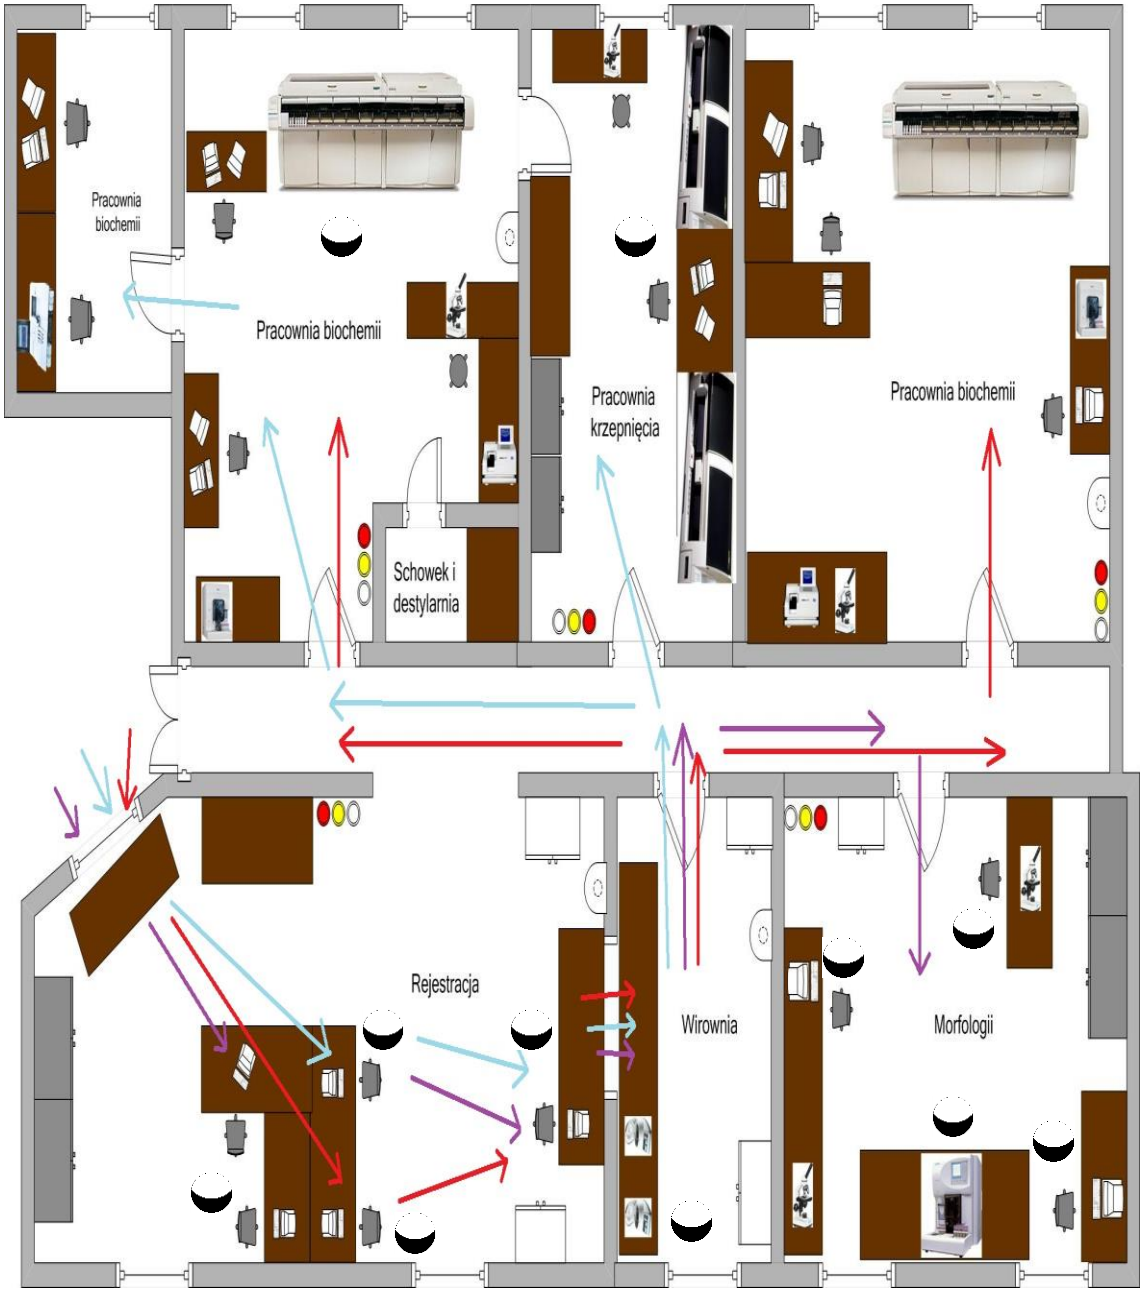
- Proces, który oznacza transformację danych wejściowych w wynikowe i odpowiada tym składnikom systemu, które przetwarzają dane. Procesy otrzymują i przesyłają dane za pośrednictwem przepływów danych.
- Przepływ danych, który opisuje zbiór danych przepływający pomiędzy dwoma obiektami w systemie.
- Magazyn danych, inaczej składnica danych służy do przechowywania danych w postaci jednorodnych kolekcji.
- Terminator - obiekt zewnętrzny w stosunku do systemu reprezentujący źródła lub miejsca przeznaczenia informacji *(Ordysiński T., 2017)*.

Ogólny schemat procesów zachodzących w laboratoriu medycznym został przedsatwiony w postaci diagramu przepływu danych. Rolę terminatora pełni klient, czyli oddział szpitalny lub pacjent. Pracownie diagnostyczne pełnią rolę magazynu danych.



Rys. 10. Ogólny schemat DPD laboratorium medycznego.
(Źródło: opracowanie własne)

Analizując przepływ próbek w laboratorium medycznym można wyróżnić trzy najczęściej występujące kategorii próbek krwi. Są to próbki krwi z niebieskim korkiem przeznaczone do badań układu krzepnięcia, próbki krwi z czerwonym korkiem przeznaczone do parametrów biochemicznych i próbki krwi z fioletowym korkiem przeznaczone do parametrów hematologicznych. Przepływ rodzajów próbek w laboratorium medycznym przedstawiony jest na poniższym schemacie.



Rys. 11. Schemat przepływu trzech rodzajów próbek z krwią w laboratorium medycznym.
(Źródło: opracowanie własne)

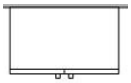
gdzie:

 - biurka

 -krzesło

 - komputer

 -umywalka

 -lodówka

 - szafka

 -pojemniki na odpady

 -mikroskop

 -wirówka

 - analizator hematologiczny XT-2000i

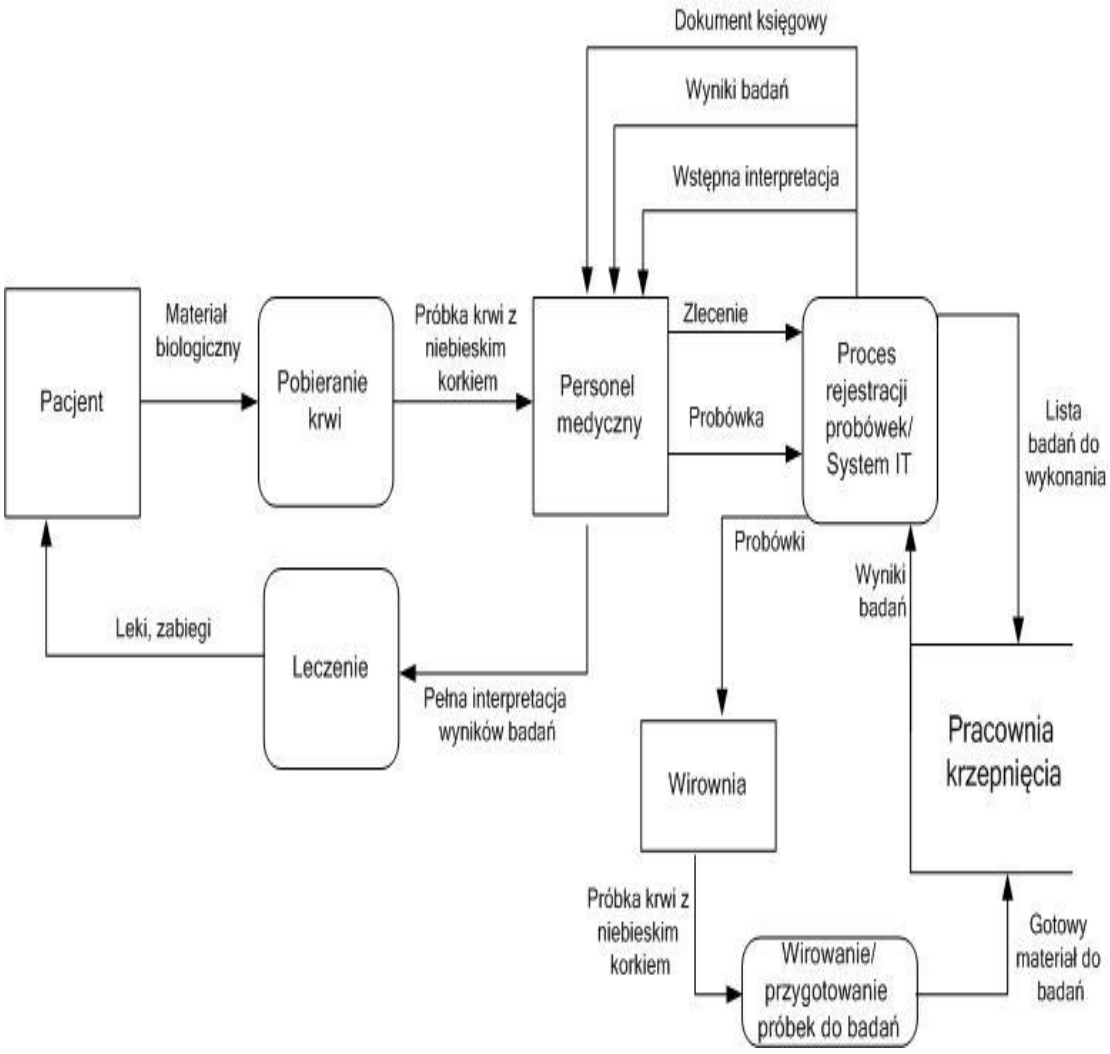
 - analizator do rutynowych oznaczeń z zakresu immunochemii Cobas e 411

 - architect ci 8200

 - cobas integra 400 plus

 - człowiek

W pracy autor skoncentrował się na szczegółowej analizie przepływu materiału biologicznego w postacie probówek krwi z niebieskim korkiem. Wybór probówek z niebieskim korkiem jest uzasadniony ilością pracowni wykonujących badania krwi z tych probówek. Na podstawie ogólnego schematu procesów zachodzących w laboratoriu medycznym przedstawionego w postaci diagramu przepływu danych, został stworzony szczegółowy diagram przepływu danych dla próbek krwi z niebieskim korkiem.



Rys. 12. Schemat przepływu trzech rodzajów próbek z krwią w laboratorium medycznym.
(Źródło: opracowanie własne)

Diagram uwzględnia wszystkie procesy związane z przepływem próbki w laboratorium zaczynając od pobrania krwi u pacjenta i kończąc wynikami badań.

8.2 Analiza danych teorią kolejek

Teoria kolejek – dziedzina matematyki zajmująca się analizowaniem systemów, w których powstają kolejki. Teoria kolejek jest dziedziną związaną z badaniami operacyjnymi, rachunkiem prawdopodobieństwa, matematyką stosowaną, jak również telekomunikacją i informatyką *(Oniszczuk, 1995)*.

W systemach, którymi zajmuje się teoria kolejek, zlecenia (np. klienci w supermarkecie) napływają do punktów obsługi (kasy) i czekają na obsłużenie w poczekalni (kolejka do kasy). Zwykle przyjmuje się, że tempo napływu klientów jest zmienną losową, co powoduje, że nawet jeżeli punkty obsługi teoretycznie obsługują klientów szybciej niż oni napływają, w systemie powstają kolejki. Kolejki wynikają z tego, że w jednej chwili klienci w ogóle nie pojawiają się przy kasie, natomiast w innej chwili pojawia się "podwójna porcja" klientów *(Oniszczuk, 1995)*.

Posiadając szczegółowy opis procesów zachodzący w laboratorium dla probówek, kolejnym krokiem jest przeanalizowanie tych procesów pod względem powstawania kolejek. W niniejszej pracy probówki z krwią pełnią rolę klientów a poszczególne działy laboratorii takie jak rejestracja lub wirownia pełnią rolę kas.

Analizując wiarygodność powstawania kolejek w rejestracji, musimy obliczyć intensywność przepływu probówek przez rejestrację.

$$\lambda = \frac{1}{M[T]} \qquad (2)$$

Gdzie:

- λ – intensywność przepływu,
- M[T] – średni czas rejestracji kolejnych próbek.

Aby obliczyć M[T] musimy posiadać informację dotyczącą ilości probówek zarejestrowanych w ciągu jednej zmiany i ile godzin trwa zmiana. Ilość probówek zarejestrowanych w ciągu jednej zmiany to czterysta sztuk, a czas trwania jednej zmiany wynosi osiem godzin.

$$M[T] = \frac{8}{400} \approx 0{,}02[T] \qquad (3)$$

$$\lambda = \frac{1}{0{,}02} = 50$$

Kolejnym etapem jest wyznaczenie intensywności przepływu rejestracji probówek.

$$\mu = \frac{1}{M} = \frac{1}{3\,\text{min}} = \frac{1}{0{,}05} = 20 \qquad (4)$$

gdzie:

- μ – intensywność przepływu rejestracji,
- M – czas rejestracji jednej próbki (3 minuty).

Czas rejestracji jednej próbki różni się od średniego czasu rejestracji kolejnych próbek ze względu na ilość badań, które mogą być zlecone przez lekarza i musza być wykonane z jednej probówki krwi pobranej u pacjenta.

Uzyskany wynik, 20 próbek rejestrowanych w ciągu godziny, będzie wykorzystany do obliczenia ρ - współczynnika przeciążenia.

$$\rho = \frac{\lambda}{\mu} = \frac{50}{20} = 2{,}5 \qquad (5)$$

Zgodnie z zasadami teorii kolejek zachodzi nierówność $p>1$, czyli liczba zgłoszeń przewyższa możliwości obsługi takiej liczby zgłoszeń. Oznacza to, że system jest niestabilny i że prawdopodobieństwo długiej kolejki się zwiększa. Osiągnięcie stanu równowagi jest tylko możliwe dzięki podjęciu radykalnych działań:

- skróceniu czasu obsługi klienta,
- zainstalowaniu dodatkowego stanowiska obsługi.

W przypadku $t \to \infty$ kolejka zwiększałaby się w nieskończoność, jednak w przypadku laboratorium czas jest ograniczony jedną zmianą, co oznacza, że do końca dnia pracownicy rejestracji mogą zarejestrować wszystkie zlecone próbki. Jednak analizując wynik można stwierdzić, że rejestracja

jest jednym z obszarów które można zaliczyć do wąskiego gardła laboratorium.

W przypadku wirowni autor wykonał identyczne obliczenia. Ilość próbek uległa zmiane ze względu na to, że nie wszystkie badania wymagają wirowania krwi. Ilość probówek w ciągu jednej zmiany to dwieście sztuk, a czas trwania jednej zmiany wynosi osiem godzin.

$$\lambda = \frac{1}{M[T]} \qquad (6)$$

$$M[T] = \frac{8}{200} \approx 0{,}04[T] \qquad (7)$$

$$\lambda = \frac{1}{0{,}04} = 25$$

Kolejnym etapem jest wyznaczenie intensywności przepływu wirowania probówek. Jednocześnie może się wirować 25 próbek, czas wirowania wynosi 10 min.

$$\mu = \frac{25}{M} = \frac{25}{10\,\text{min}} = \frac{25}{0{,}167} \approx 149{,}7 \qquad (8)$$

$$\rho = \frac{\lambda}{\mu} = \frac{25}{149{,}7} \approx 0{,}167 \qquad (9)$$

Zachodzi nierówność $p<1$, czyli liczba zgłoszeń nie przewyższa możliwości obsługi takiej liczby zgłoszeń. Oznacza to, że system jest stabilny i że prawdopodobieństwo powstania długiej kolejki maleje.

W wirowni są dostepne 2 wirówki.

$$X = \frac{\rho}{2} \approx 0{,}084 \qquad (10)$$

gdzie:

- X – stosunek współczynnik przeciążenia do ilości kanałów obsługi

Posiadając potrzebne dane można wyliczyć ρ0 - wiarygodność, że probówka będzie czekała w kolejce.

$$\rho_0 = [1 + \frac{\rho}{1!} + \frac{\rho^2}{2!} + \frac{\rho^3}{2*2!} * \frac{1}{1-X}]^{-1} = \\ = [1 + \frac{0{,}167}{1} + \frac{0{,}167^2}{2} + \frac{0{,}167^3}{4} * \frac{1}{1-0{,}084}]^{-1} \approx 0{,}85 \quad (11)$$

Analizując wyniki wirowni można stwierdzić, że ten obszar nie zaliczycza sie do wąskiego gardła laboratorium i posiada duże moce przerobowe.

W podobny sposób zostały olbiczone kolejne etapy w przepływie próbówek przez laboratorium. Za pomocą teorii kolejek zostały wyznaczone miejsca występowania wąskich gardeł w trakcie przepływu próbek przez laboratorium, co w znaczny sposób ułatwiło uporządkowanie danych i usprawniło proces tworzenia modelu matematycznego.

9.SPECYFIKA WYKORZYSTANIA DANYCH METOD W LABORATORIUM

W niniejszej pracy autor skupił się na opracowaniu metody uporządkowania przepływu danych w podmiocie gospodarczym. W opracowaniu zostały wykorzystane dane uzyskane w laboratorium medycznym w szpitalu klinicznym. Jest to nietypowy podmiot gospodarczy i wykorzystanie modelu przepływu danych i teorii kolejek jest nie oczywistym wyborem. Specyfika wybranego podmiotu polega na tym, że głównym procesem jest łańcuch zachodzących reakcji chemicznych np. w próbkach krwi w zależności od odczynników znajdujących się w poszczególnych analizatorach. Reakcje w badaniach klinicznych są uzależnione biologicznie i na czas ich przebiegu nie mamy dużego wpływu. Dodatkowo warto podkreślić, że analizatory wykorzystywane w laboratorium mają wysoki poziom technologiczny i usprawnienie części technicznej laboratorium jest wykluczone. W porównaniu do przedsiebiorstw produkcyjnych laboratorium nie posiada planu obciażeń na kolejne tygodnie lub miesiące. Na obciążenie laboratorium wpływa dużo czynników zewnętrznych, takich jak:

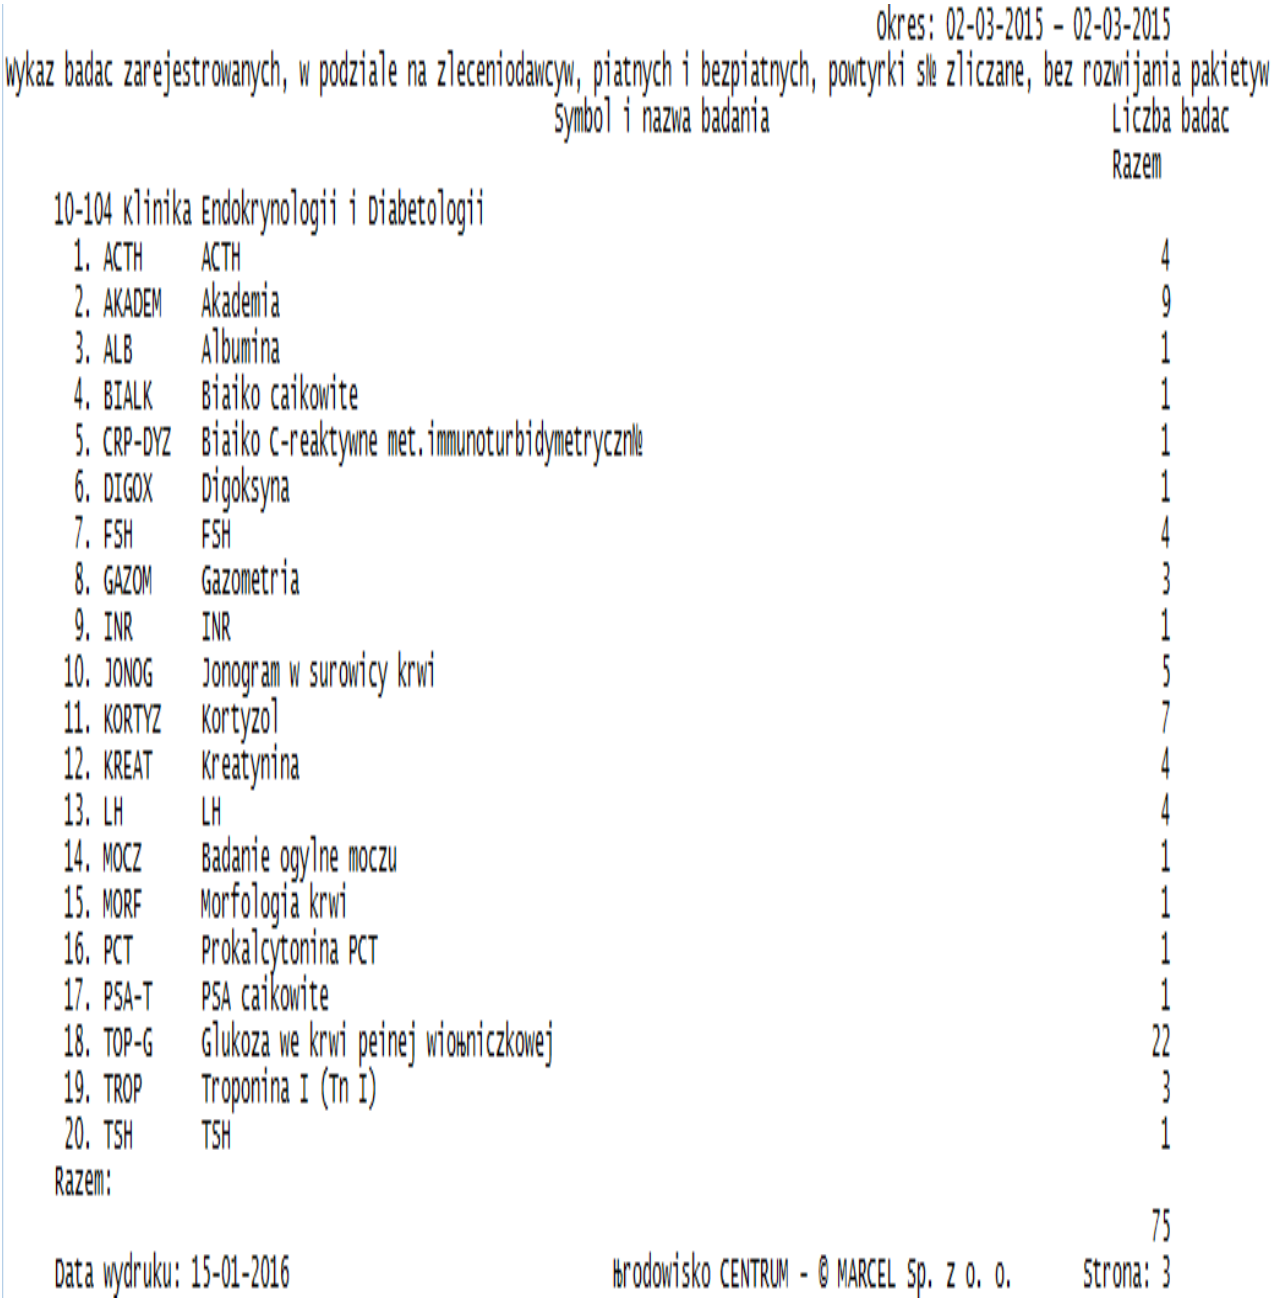
- sezonowość (pory roku),

- epidemie,
- nowa terapia.

Dlatego dla analizy danych wygenerowano 365 raportów dotyczących ilości zleconych badań przez każdą klinikę szpitala w jednym dniu. Do analizy danych uzyskanych w laboratoum teorią kolejek były obliczone średnie wartości. Jest to uzasadnione sezonowością obciążeń. Dla tego teoria kolejek służyła jako narzędzię do wyznaczenia wąskich gardeł a nie było wykorzystane jako metoda, która może rozwiązać brak rytmiczności pracy w laboratorium. W ponizszych punktach pracy skupiono się na próbie stworzenia uniwersalnego algorytmu harmonogramowania procesów który uwzględnia większa ilość zależności.

10. KONSTRUKCJA MODELU MATEMATYCZNEGO

Pierwszym krokiem w opracowaniu procesu jest zapoznanie się z rodzajami raportów i formatem, w którym można je wygenerować. W przypadku analizowanego laboratorium jest to format plików pdf i txt. Te pliki niosą w sobie dane o ilości poszczególnych badań w poszczególnych klinikach w ciągu jednego dnia, tygodnia lub roku. Raporty tworzą się automatycznie na podstawie danych, które są codziennie wprowadzanie przez pracowników rejestracji. Do analizy zostały wybrane dzienne raporty. Uzasadnieniem wyboru autora była ilość danych, które można uzyskać analizując taką ilość raportów. W przypadku dziennych raportów łatwiej znaleźć powiązania pomiędzy klinikami a rodzajem badań, a dane uzyskane z analizy będą bardziej dokładne. Poniżej jest przedstawiony fragment raportu wygenerowane w laboratorium.



Okres: 02-03-2015 - 02-03-2015

Wykaz badac zarejestrowanych, w podziale na zleceniodawcyw, piatnych i bezpiatnych, powtyrki s№ zliczane, bez rozwijania pakietyw

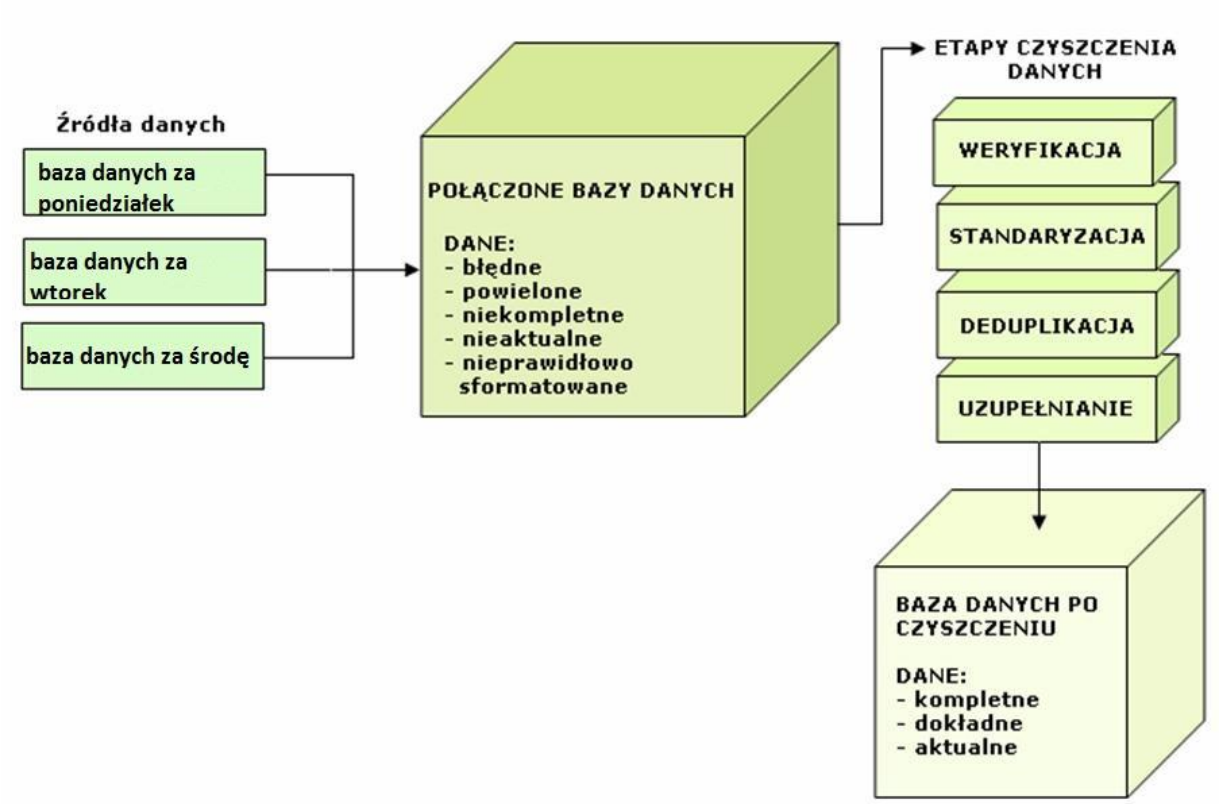
	Symbol i nazwa badania		Liczba badac Razem
10-104 Klinika Endokrynologii i Diabetologii			
1.	ACTH	ACTH	4
2.	AKADEM	Akademia	9
3.	ALB	Albumina	1
4.	BIALK	Biaiko caikowite	1
5.	CRP-DYZ	Biaiko C-reaktywne met.immunoturbidymetryczn№	1
6.	DIGOX	Digoksyna	1
7.	FSH	FSH	4
8.	GAZOM	Gazometria	3
9.	INR	INR	1
10.	JONOG	Jonogram w surowicy krwi	5
11.	KORTYZ	Kortyzol	7
12.	KREAT	Kreatynina	4
13.	LH	LH	4
14.	MOCZ	Badanie ogylne moczu	1
15.	MORF	Morfologia krwi	1
16.	PCT	Prokalcytonina PCT	1
17.	PSA-T	PSA caikowite	1
18.	TOP-G	Glukoza we krwi peinej wiowniczkowej	22
19.	TROP	Troponina I (Tn I)	3
20.	TSH	TSH	1
Razem:			75

Data wydruku: 15-01-2016 Wrodowisko CENTRUM - © MARCEL Sp. z o. o. Strona: 3

Rys. 13 Fragment raportu z kliniki endokrynologii z dnia 02.03.15.
(Źródło: opracowanie własne)

Te dane są różnorodne i czasami się powtarzają, dla tego kolejnym krokiem jest proces czyszczenia danych. Czyszczenie danych jest metodą wykrywania i usuwania lub korekty informacji w bazie danych w przypadku, gdy są one błędne, powielane, niedokładne, nieaktualne, zbędne bądź nieprawidłowo sformatowane. Dodatkowo czyszczenie zapewnia bezbłędne łączenie danych z odrębnych baz. Procedura czyszczenia danych opiera się na algorytmach tworzonych przez programistów i

administratorów baz danych, które eliminują błędy powstałe podczas ręcznej edycji bazy danych.



Rys. 14 Schemat czyszczenia danych.
(Źródło: http://standaryzacjadanych.hoga.pl/czyszczenie.asp)

Czyszczenie danych głównie wykorzystywane jest w bankowości, firmach ubezpieczeniowych, handlu, telekomunikacji i transporcie.
Czyszczenie danych składa się z takich procedur jak:

- weryfikacja,
- standaryzacja,
- deduplikacja (eliminowanie powtarzających się części w zbiorze danych),
- uzupełnianie danych *(http://standaryzacjadanych.hoga.pl)*.

Posiadając informację o treści plików i ich formacie warto zastanowić się nad standaryzacją otrzymanych danych. Pierwszym krokiem jest połączenie wygenerowanych plików txt w jeden duży plik opisujący miesiąc albo rok. Kolejnym krokiem jest stworzenie bazy danych, która pozwoliłaby na analizę wygenerowanych danych nie tylko z punktu widzenia jednego dnia, ale też z punktu widzenia miesiąca albo pory roku

jak również kliniki i konkretnego badania. Żeby połączyć wygenerowane pojedyncze pliki w jeden rozbudowany plik jest wybrany, jako instrument, język programowania python. Python – język programowania wysokiego poziomu ogólnego przeznaczenia, o rozbudowanym pakiecie bibliotek standardowych, którego ideą przewodnią jest czytelność i klarowność kodu źródłowego. Jego składnia cechuje się przejrzystością i zwięzłością.
Python wspiera różne paradygmaty programowania: obiektowy, imperatywny oraz w mniejszym stopniu funkcyjny. Posiada w pełni dynamiczny system typów i automatyczne zarządzanie pamięcią. Podobnie jak inne języki dynamiczne jest często używany jako język skryptowy. Interpretery Pythona są dostępne na wiele systemów operacyjnych *(https://www.python.org)*. Kod stworzony w Python jest przytoczony poniżej.

```
#!/usr/bin/env python

# -*- coding: utf-8 -*-

from pyparsing import *

ParserElement.setDefaultWhitespaceChars('
\t')

#ParserElement.setDefaultWhitespaceChars('')

newline = LineEnd ()

my_alpha_rus = alphas  + u + ".!?"

my_alpha_pl = alphas + u"[ćęóńśŚłŁążŻ©_]"  +
".!?"

#profilToken = u

#napravToken = u

#grupToken = u

#denyToken = u

#CODEBLOK = Word(nums, exact=2)

CODEBLOK = Word(nums, min=2, max=3)
```

```
num = Word(nums)

LPAREN = u"("

RPAREN = u")"

COMA = u","

grupToken = Word(u"Zleceniodawca")

word = Word( my_alpha_pl )  | num | LPAREN |
RPAREN | u":" | u";" | u"-" | u"%" | u"–" |
u"«" | u"»" | u" " | u" " | u"/"  | u"—" |
u"+" | u"\"" | COMA

emptyline = Suppress( newline)

#zakaz =

words = OneOrMore(word)

words.setParseAction( lambda tokens: "
".join(tokens) )

nonemptyline =  words + Suppress(newline)

nonemptyline.setParseAction( lambda tokens:
" ".join(tokens) )

numline = Suppress( num("nomer") + u".") +
words("nazwa") +  Suppress(newline)

#numline.setParseAction( lambda tokens: "
".join(tokens) )

data = Suppress( Word(my_alpha_pl, exact=5)
+ Literal(u":") ) + words("data") +
Suppress(newline)

zakaz = Suppress( Word(my_alpha_pl,
exact=13) + Literal(u":") ) + words("from")
+ Suppress(newline)
```

```
#zakaz.setParseAction( lambda tokens: "
".join(tokens) )
paket = Group(data + Suppress(nonemptyline +
nonemptyline + nonemptyline + nonemptyline
+nonemptyline) +zakaz("from") +
OneOrMore(numline))("paket")
line = paket |
Suppress(nonemptyline("line")) |
emptyline("empty")
lines = OneOrMore(line)
zakazy = lines + zakaz

#profil = Suppress(LineStart()) +
Word(my_alpha_rus, exact=1)("profilCode") +
Suppress( newline) + Suppress(LineStart())
+ line("profilName")

#naprav = Suppress(LineStart()) +
CODEBLOK("napravCode") + Suppress( newline)
+ Suppress(LineStart()) + line("napravName")

#grup   = Suppress(LineStart()) +
CODEBLOK("napravCode") + Suppress(u" ") +
CODEBLOK("grupCode") + Suppress( newline) +
Suppress(LineStart()) + line("grupName") #+
Suppress(LineStart()) + (numline("grupMSKO")
| Suppress(line))

#spec   = Suppress(LineStart()) +
CODEBLOK("napravCode") + Suppress(u" ") +
CODEBLOK("grupCode") + Suppress(u" ") +
CODEBLOK("specCode") + Optional(Suppress(
u"-") + CODEBLOK("specnapCode")) + Suppress(
newline) + Suppress(LineStart()) +
line("specName") +
Optional(Suppress(LineStart()) +
(numline("codURO") ^ Suppress(line) ^
Suppress(LineStart()+LineEnd())))
```

```
#parsetable = OneOrMore(Group(profil +
ZeroOrMore(Group(naprav +
ZeroOrMore(Group(grup + ZeroOrMore(Group(
spec
)("spec")))("grup")))("naprav")))("profil"))

#parsetable = profil + naprav + grup + spec

with open ("./Czerwiec/01,06.txt", "r") as
myfile:

#with open ("./01,06.txt", "r") as myfile:

#with open ("tablica4.txt", "r") as myfile:

    data=myfile.read()

data = data.decode('utf-8')

#data = data.decode('1250')

l = lines.parseString(data)

ll = l.asXML("DOC").encode('utf-8')

print l.asXML("DOC")

with open ("outdata.txt", "w") as myfile:

    myfile.write(ll)
```

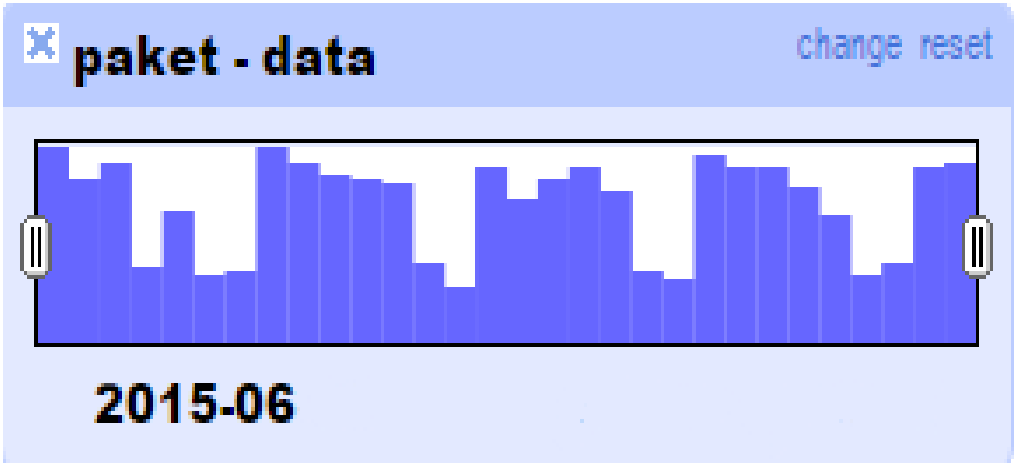
Rys. 15 Fragment kodu stworzonego w Python, który został wykorzystany do łączenia plików i czyszczenia danych.
(Źródło: opracowanie własne)

Po utworzeniu tego kodu pojedyncze pliki udało się połączyć w jeden plik, który ma większą wagę informacyjną *(Knowlton James O., 2010)*. Jest to już duża baza danych, która niesie w sobie różnorodną informację. Big data – termin odnoszący się do dużych, zmiennych i różnorodnych zbiorów danych, których przetwarzanie i analiza jest trudna ale jednocześnie wartościowa, ponieważ może prowadzić do zdobycia nowej wiedzy. W praktyce pojęcie dużego zbioru danych jest względne i oznacza sytuację, gdy zbioru nie da się przetwarzać przy użyciu trywialnych, powszechnie dostępnych metod. Aby znaleźć potrzebną informację w stworzonej bazie

danych należy wykorzystać program Google OpenRefine. Główny cel programu - czyszczenie i przetwarzanie danych. Wśród jego głównych cech można wymienić:

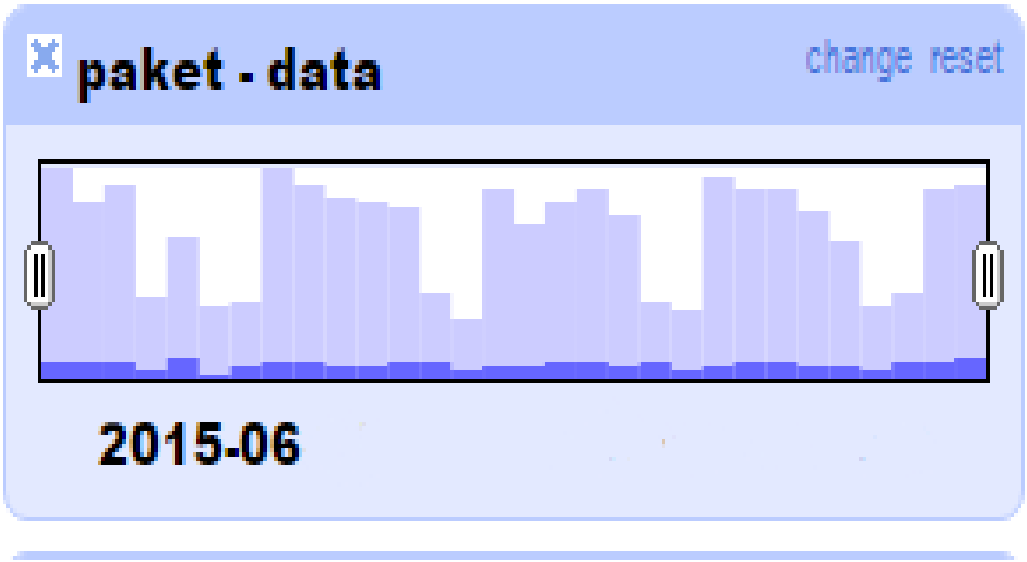
- Możliwość szybkiego zorientowania się w dużej ilości informacji.
- Przetwarzanie danych w wymaganym formacie, do zrobienia podstawowych obliczeń.
- Filtrowanie i łączenie danych.
- Znalezienie błędów i niedokładności - na przykład zbyt dużych liczb, słów zamiast liczb, pustych wartości.
- Automatyczne wykrywanie ewentualnych błędów lub rozbieżności w nazwach, umożliwia sporządzenie danych jednego typu (grupowanie wpisów tekstowych).

Zaletą tego programu jest jego prostota. Program nie jest trudniejszy niż, na przykład, MS Excel. Wszystkie zadania wymienione powyżej mogą być wykonane w innych programach, bazach danych i językach programowania. Google OpenRefine jest bezpłatnym programem specjalizowanym do czyszczenia danych. Za pomocą Google OpenRefine można wyczyścić bazę danych, w której pozostaną tylko informacje potrzebne do analizy. Kolejnym krokiem jest sprawdzenie i poprawienie błędów zapisu danych. W jednym pliku mogą sie znajdować dwie nazwy tego samego badania zapisane z dużej i małej litery. Za pomocą oprogramowania uda się ujednolicić nazwy badań i zsumować dane dotyczące tych badań.



Rys. 16 Histogram ilości badań zleconych przez wszystkie kliniki w ciągu jednego miesiąca. *(Źródło: opracowanie własne)*

Słupki na rysunku 16 pełną funkcję dni. Na rysunku widać 30 słupków – dni miesiąca oraz różnicę ilości zlecanych badań w poszczególnych dniach – wysokość słupków.

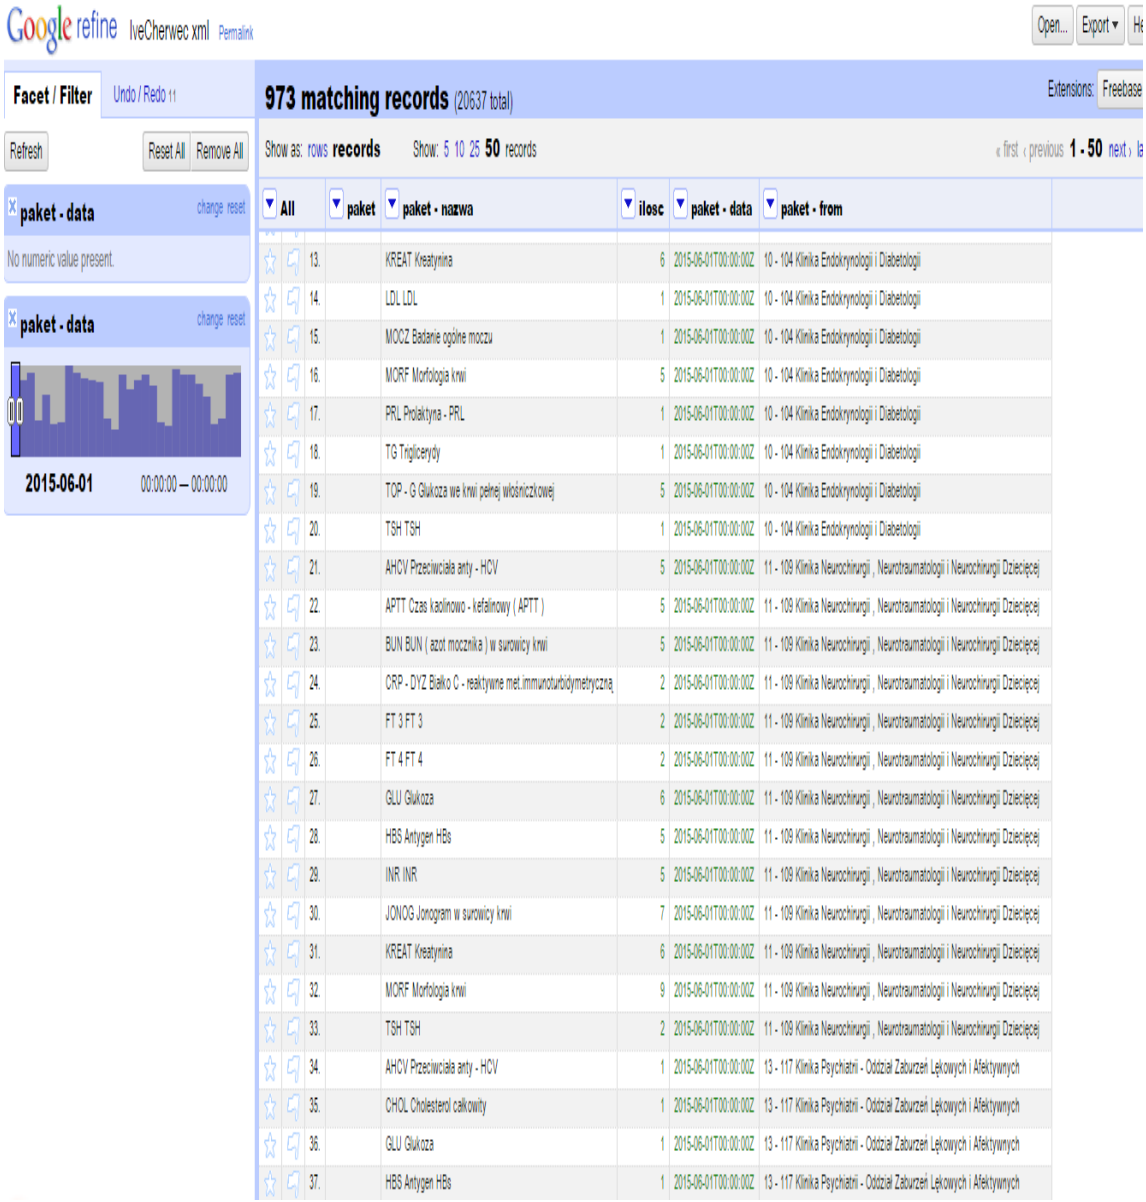


Rys. 17 Histogram przedstawia ilość zleceń z kliniki kardiologii i całkowitą ilość zleceń ze szpitalu. *(Źródło: opracowanie własne)*

Jasne słupki na rysunku 17 pełną funkcję słupków z rysunku 16, czyli przedstawiają ilość zleconych badań przez wszystkie kliniki w jednym dniu. Ciemne słupki przedstawiają ilość zleconych badań przez klinikę kardiologii. Analizując rysunek 17 można łatwo zaobserwować stosunek ilości zlecanych badań przez klinikę kardiologii do całkowitej ilości zlecanych badań.

Otrzymane wyczyszczone dane można wykorzystać w analizie wydajności laboratorium. Pozwolą one wyznaczyć klinikę, która zleca najwięcej badań, wyznaczyć dni, kiedy laboratorium przetwarza najwięcej próbek i kiedy obciążenie laboratorium jest największe. Posiadając taką informację można zacząć analizę laboratorium pod względem optymalizacji i stabilności.

W ramach badań zostanie skonstruowany rozbudowany model danych dotyczących obciążeń laboratorium klinicznego w określonym dniu, miesiącu i podzielony na określone kliniki i rodzaje badań.



Rys. 18 Zrzut ekranu przedstawia rodzaje i ilości zleconych badań przez poszczególne kliniki w programie Google OpenRefine. *(Źródło: opracowanie własne)*

Rysunek 18 pokazuje w jaki sposób sortowane są dane. Na rysunku są przedstawione kolumny z nazwą badania, ilość zleconych badań, data, zleceniodawca, czyli klinika. Na rysunku 18 dane są posortowane dla jednego dnia 01-06-2015.

Analizując otrzymane histogramy można wywnioskować, że największe obciążenie jest w poniedziałki i wtorki a od piątku do niedzieli obciążenie jest dwa razy mniejsze. Jednak te histogramy się różnią w zależności od miesiąca i pory roku. Dla tego dane zostały połączone w Big Data i przy pomocy tensorowej metody reprezentacji danych stworzono wizualizację jak się zmienia ilość i rodzaj badań w zależności od dnia. Wizualizacja

została stworzona dla 366 dni. Do analizy została wykorzytsana metoda CP wykorzytsywana w języku programowania R. Metoda CP rozkłada tensor na sumę produktów zewnętrznych wektorów. Na przykład dla 3-kierunkowego tensora X rozkład CP można zapisać jako

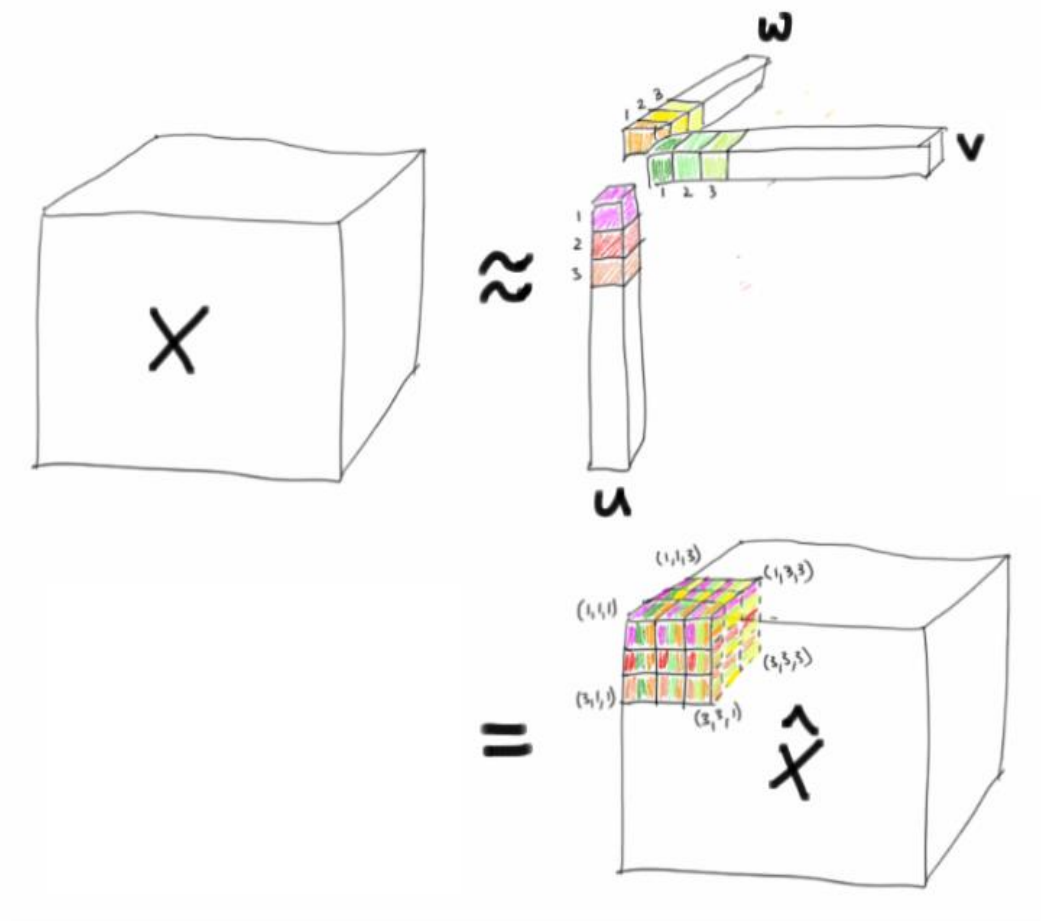
$$X \approx \sum_{r=1}^{R} u_r \circ v_r \circ w_r =: \widehat{X}, \qquad (12)$$

gdzie:

- R> 0 i u_r, v_r, w_r są wektorami o odpowiednich wymiarach,
- notacja „o” oznacza iloczyn zewnętrzny tensorów, tj.

$$x_{ijk} \approx \hat{x}_{ijk} = \sum_{r=1}^{R} u_{ri} v_{rj} w_{rk}. \qquad (13)$$

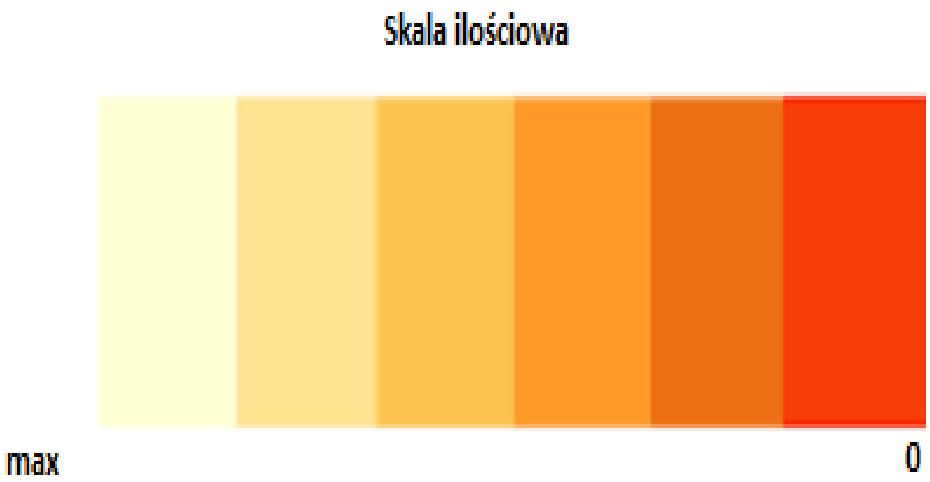
Odpowiedni rozkład CP ma zatem następującą postać (https://www.alexejgossmann.com):



Rys. 19 Rysunek przedstawia rozkład CP dla 3-kierunkowego tensora X.
(Źródło: https://www.alexejgossmann.com/tensor_decomposition_CP/)

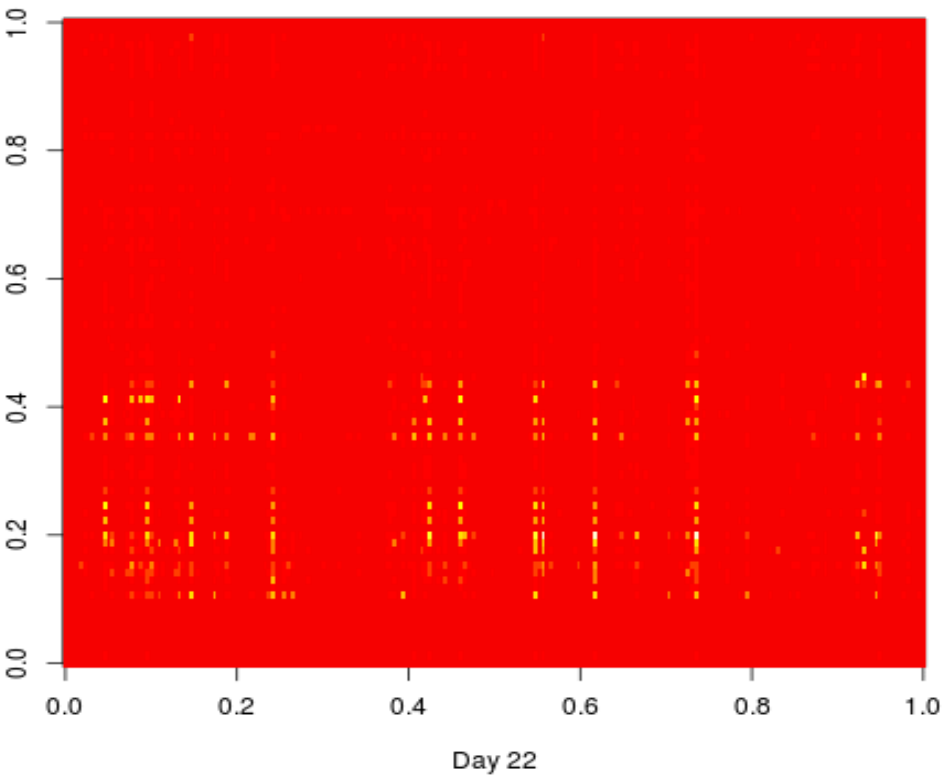
Poniżej zostały umieszczone przykładowy dni które obrazują ilość i rodzaj badań w zależności od dnia. Ze względu na brak możliwości zobrazowania rozkładu CP w postaci 3D rysunki rozkładu CP spłaszczono do postaci 2D.

Tensorowa metoda reprezentacji danych polega na założeniu, że dane wejściowe mają przypisaną wartość. Wizualizacja przedstawia różne rodzaje badań zleconych w 22, 23, 24 i 25 dniu kalendarzowym. Kolor punktów definiuje ilość badań danego rodzaju. Biały kolor oznacza dużą liczbę badań a kolor, który tylko odcieniem różni się od tła oznacza małą liczbę badań. Oś x odpowiada ilości klinik, które zlecają badania. Oś y odpowiada rodzajom badań, które są możliwe do wykonania w laboratorium. Oś z odpowiada ilości badań zleconych w danym dniu przez klinikę. Skala kolorów jest przedstawiona poniżej.

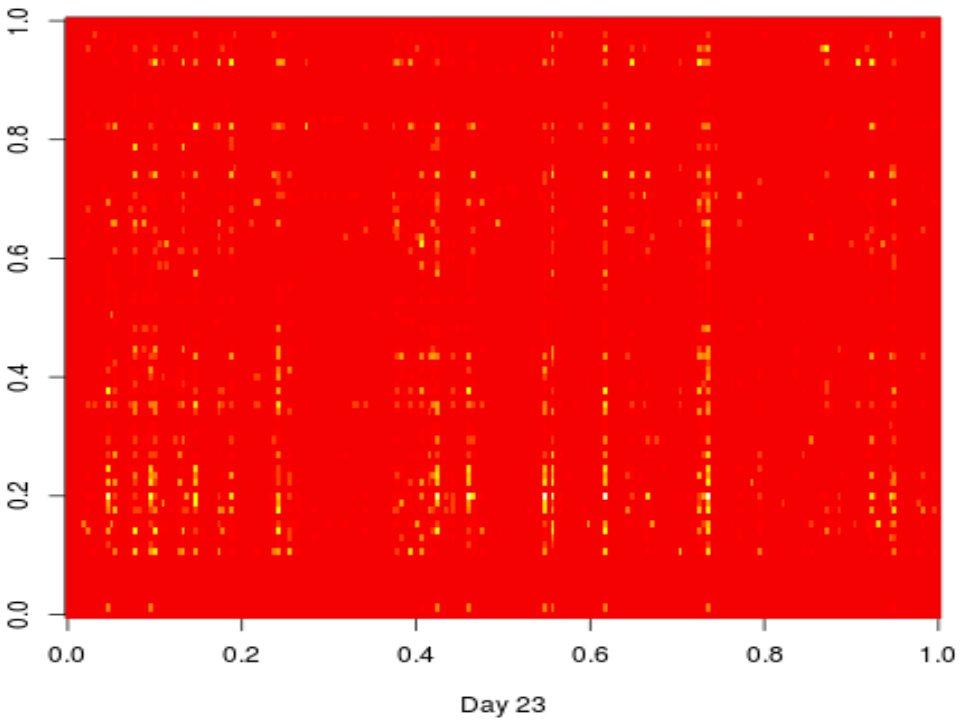


Rys. 20 Skala ilościowa dla rozkład CP. *(Źródło: opracowanie własne)*

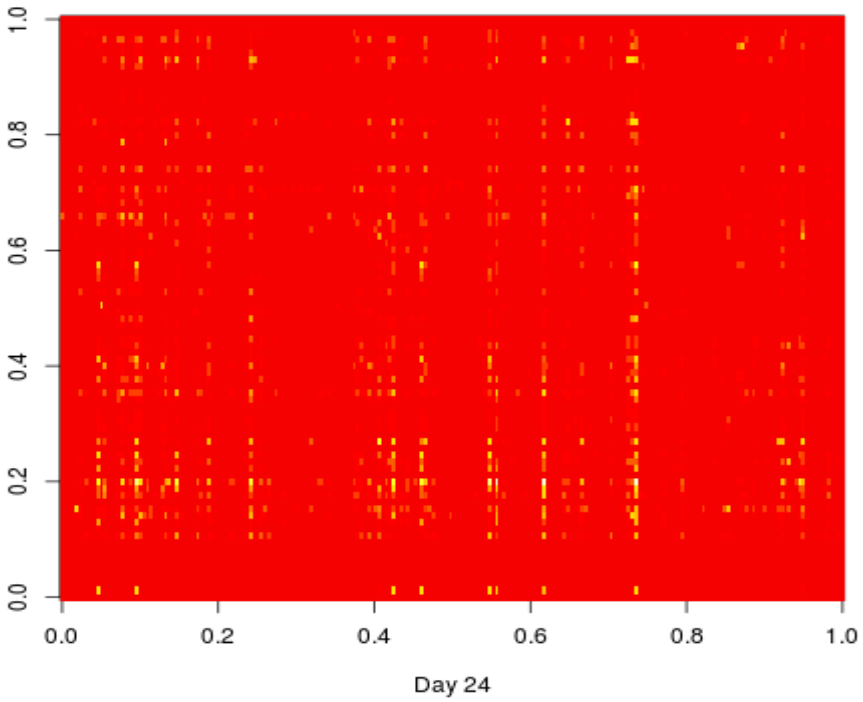
Porównując wizualizację 22 i 23 dnia, można zauważyć duże różnice, które są spowodowane tym, że 22 dzień kalendarzowy to była niedziela i obciążenia laboratorium było znacznie mniejsze. Analizując wizualizacje kolejnych dni można zobaczyć różnicę w rodzaju i ilościach zlecanych badań.



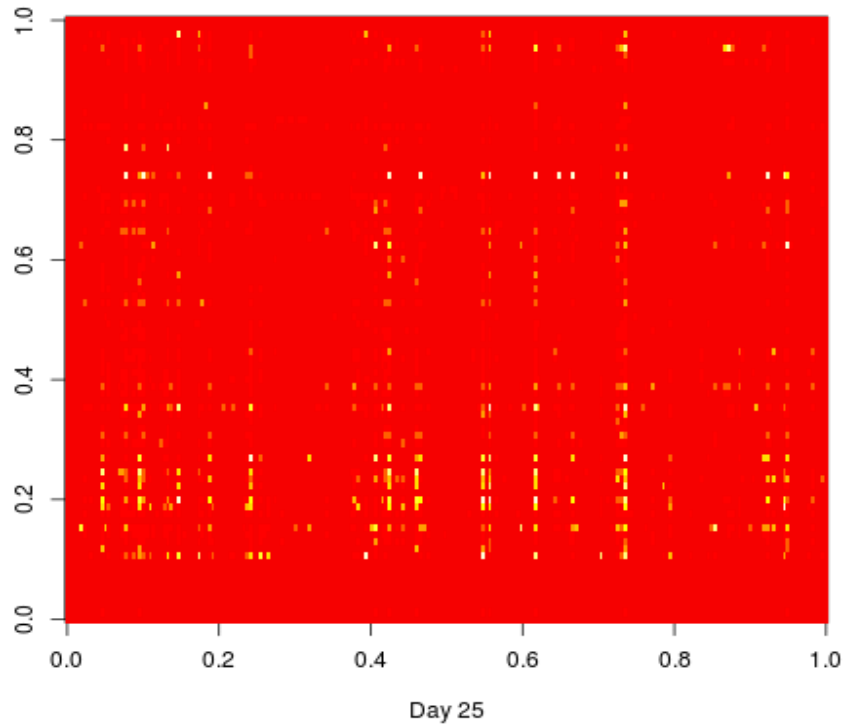
Rys. 21 Rozkład CP dla 22 dnia kalendarzowego. *(Źródło: opracowanie własne)*



Rys. 22 Rozkład CP dla 23 dnia kalendarzowego. *(Źródło: opracowanie własne)*

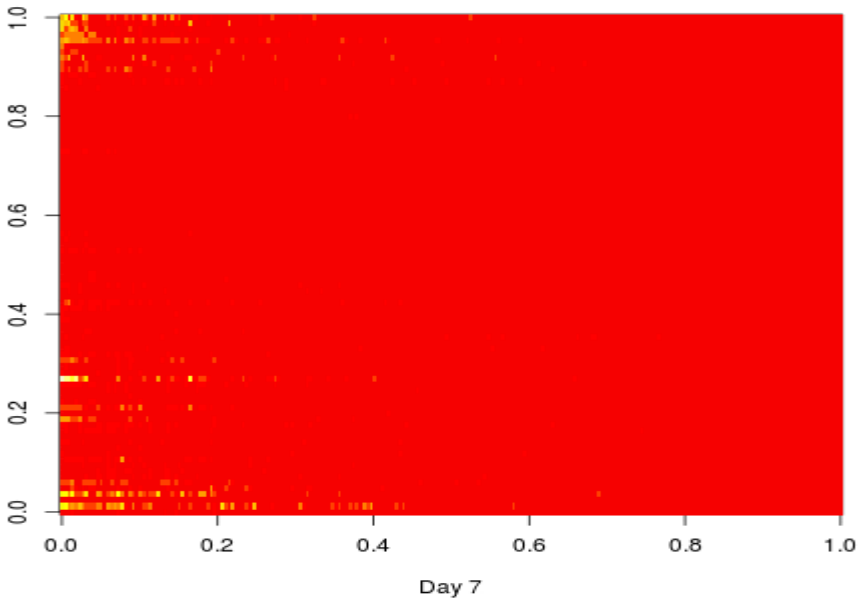


Rys. 23 Rozkład CP dla 24 dnia kalendarzowego. *(Źródło: opracowanie własne)*

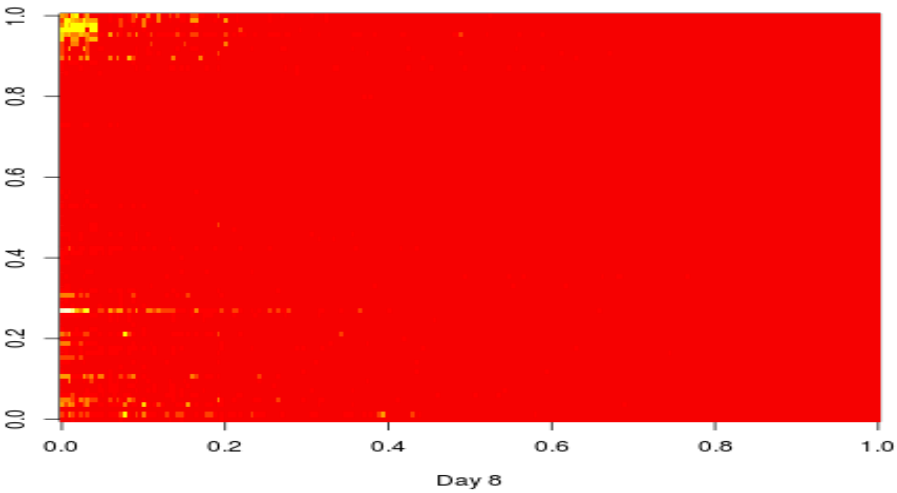


Rys. 24 Rozkład CP dla 25 dnia kalendarzowego. *(Źródło: opracowanie własne)*

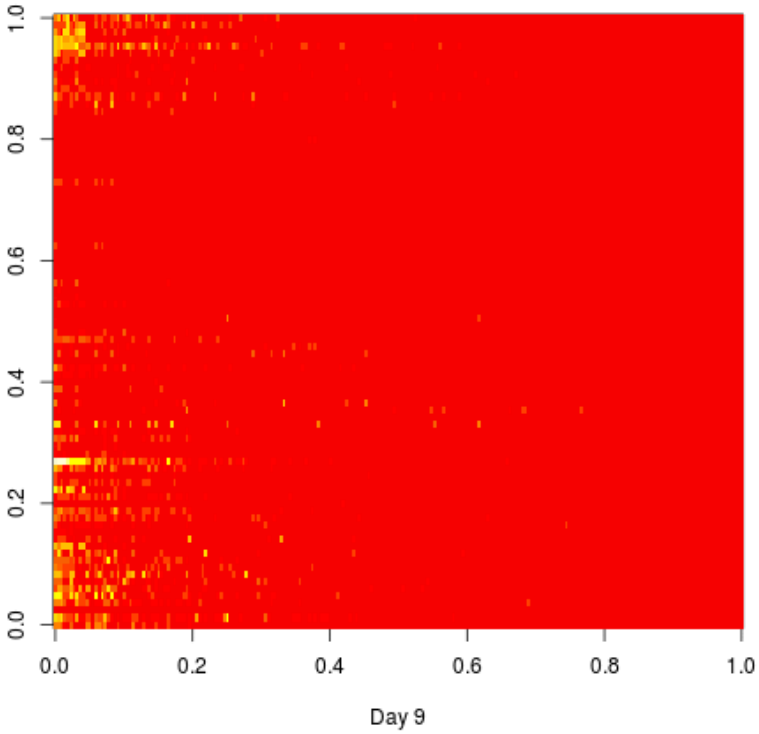
Przy pomocy tensorowej metody reprezentacji danych udało się zobrazować również zależność rodzaju i ilości badań w zależności od klinik zlecających badania. Do analizy zostały wytypowane badania, które nie są ogólne. Z Rozkładu CP można wywnioskować, że tylko niektóre kliniki stosują podobne rodzaje badań, również można stwierdzić, że większość klinik nie zleca w dużych ilościach specjalistycznych badań.



Rys. 25 Rozkład CP dla 7 dnia kalendarzowego dla wybranych badań.
(Źródło: opracowanie własne)



Rys. 26 Rozkład CP dla 8 dnia kalendarzowego dla wybranych badań.
(Źródło: opracowanie własne)

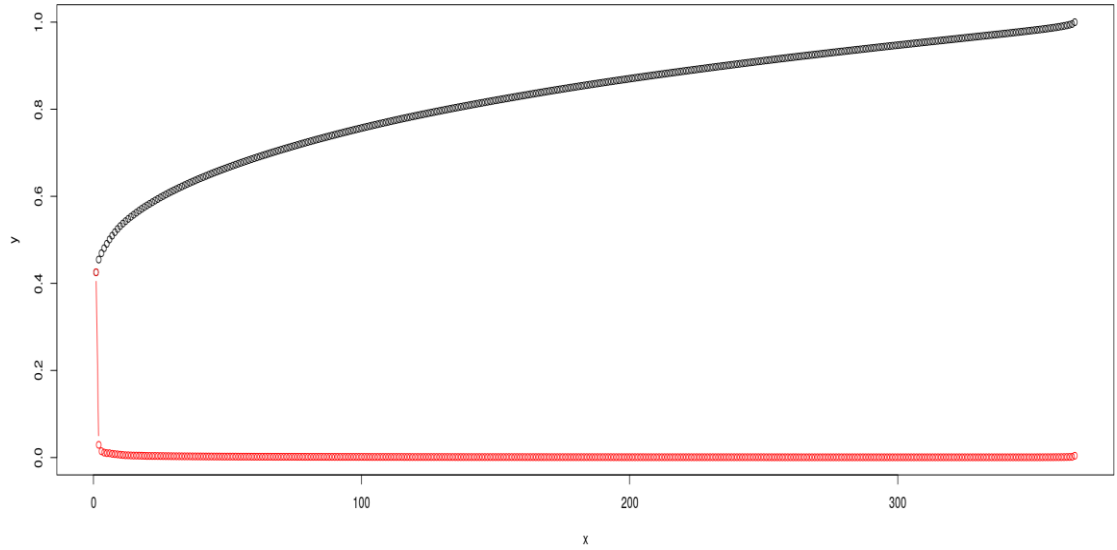


Rys. 27 Rozkład CP dla 9 dnia kalendarzowego dla wybranych badań.
(Źródło: opracowanie własne)

Na rysunkach 25, 26, 27 oś x odpowiada ilości klinik, które zlecają badania. Oś y odpowiada rodzajom specjalistycznych badań, które są zlecane przez kliniki. Oś z odpowiada ilości badań zleconych w danym dniu przez klinikę. Skala kolorów jest przedstawiona na rysunku 20.

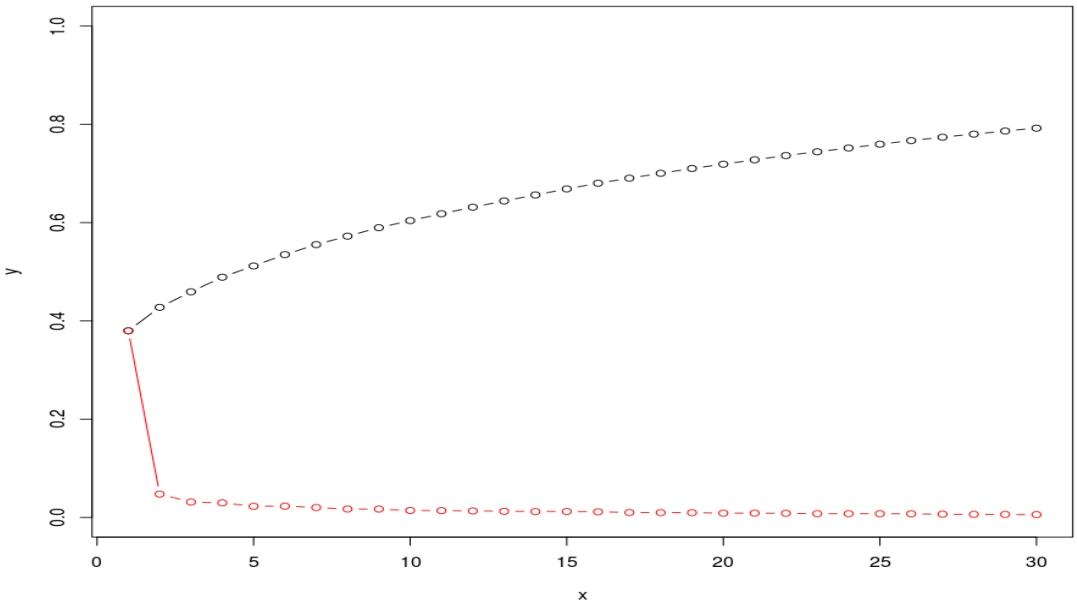
Kolejnym etapem tworzenia modelu matematycznego było wyznaczenie kryterium powiązań danych. Posiadanie kryterium umożliwia redukcje wymiaru danych. Aby określić ilość potrzebnych składowych, uznać które składowe będą nieistotne i które można będzie pominąć w pracy wykorzystano kryterium wykresu osypiskowego. Na osi odciętych zaznaczono numer wartości własnej (wartości własne uporządkowano w kolejności nierosnącej), na osi rzędnych naniesiono wielkość wartości własnej. Powstałe punkty są łączone liniami. Otrzymany wykres nazywany jest wykresem piargowym *(Gromada M., 2009)*. Warto zwrócić uwagę, że pierwsze dwie wartości istotnie różnią się od pozostałych, wykazując trend liniowy w niewielkim spadku. W takim przypadku pomijamy wszystkie składowe główne poza dwiema pierwszymi. Oznacza to, że dane uzyskane w laboratorium posiadają dwa istotne kryteria (zależności). Po

szczegółowej analizie autor stwierdził, że jest to podział na dni robocze i dni weekendowe.



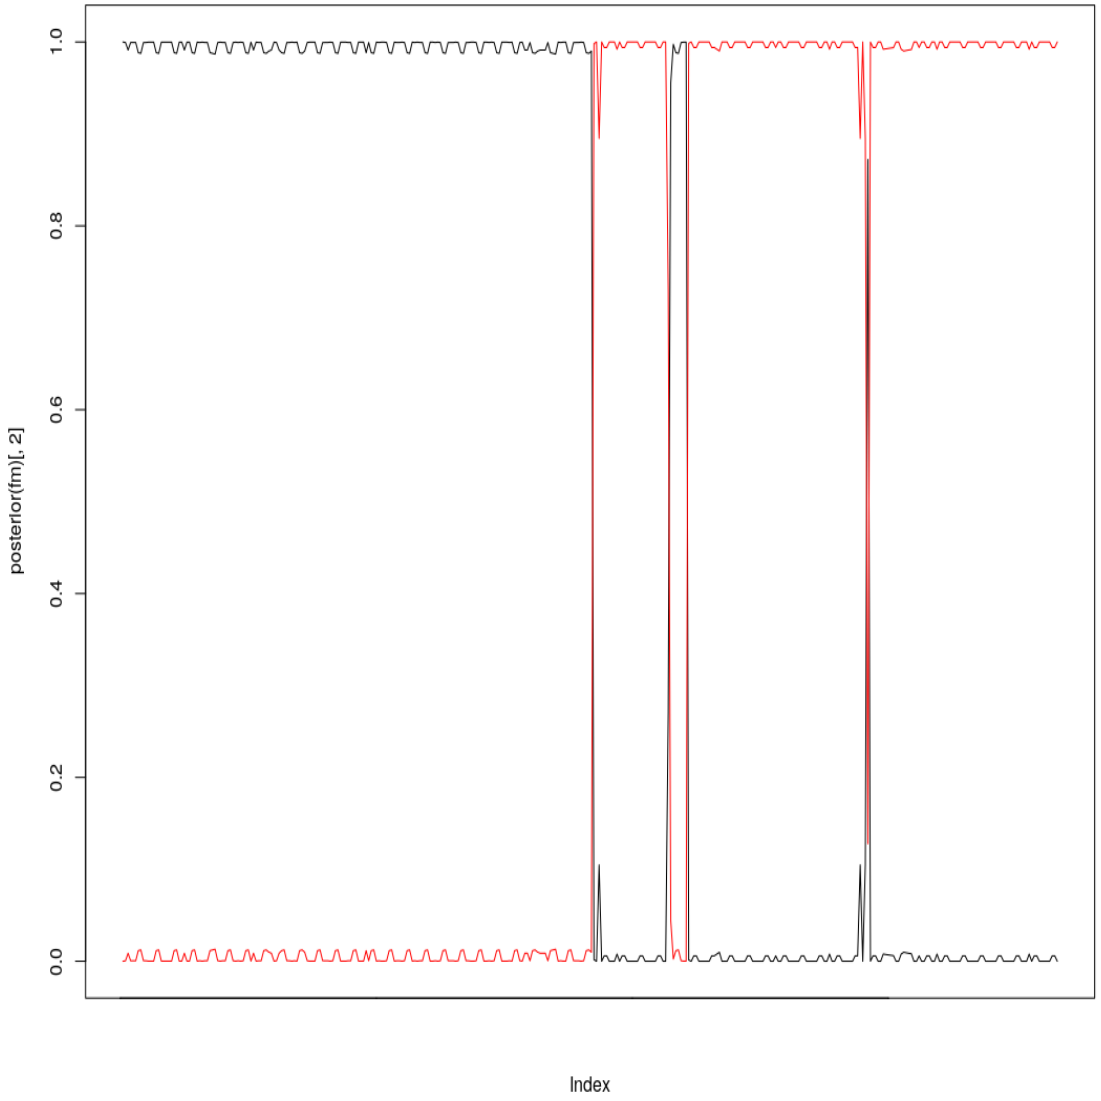
Rys. 28 Wykres piargowy powiązań danych. *(Źródło: opracowanie własne)*

Poniżej jest przedstawiona powiększona wersja wykresu piargowego.



Rys. 29 Powiększony wykres piargowy powiązań danych.
(Źródło: opracowanie własne)

Analizując dane zauważono również wpływ poru roku na obciążenia laboratorium. Wykres przedstawia ilości zlecanych badań przez przychodnie i kliniki przed rozpoczęciem i w trakcie okresu letniego.



Rys. 30 Wykres ilości zlecanych badań przed rozpoczęciem i w trakcie okresu letniego.
(Źródło: opracowanie własne)

Linie na rysunki pełnią rolę trybów pracy laboratorium. Czerwona linia tryb 1 a czarna linia tryb 2. Tryby między sobą różnią się ilością wykonywanych badań i można założyć, że w momencie przełączenia się laboratorium na tryb z mniejszym obciążeniem nie są wykorzystywane

wszystkie moce przerobowe podmiotu gospodarczego. Założenie można uzasadnić również okresem urlopowym.

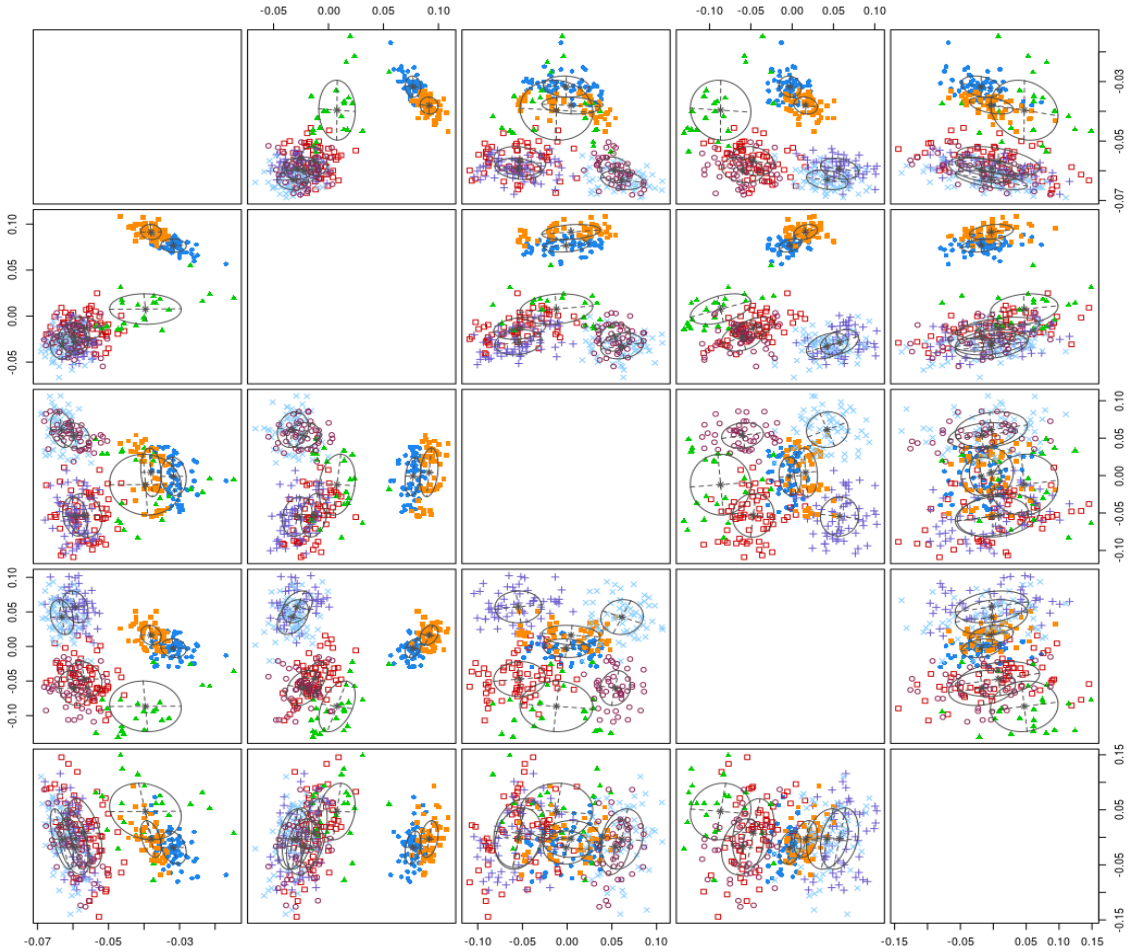
Szpital ma stały przepływ pacjentów, a czas ich przybycia i potrzeba wykonania analiz nie zależą od kalendarza. Jednak możliwość zrealizowania badań zależy od kalendarza. Dlatego ustalona liczba badań w tym okresie jest rozdzielana w różnych proporcjach między dniami, w których można to zrobić, pod względem harmonogramu laboratorium i kliniki. Do obliczeń autor wykorzystał analizę czynnikową. Analiza czynnikowa to metoda statystyczna, której celem jest opisanie zależności między zaobserwowanymi, skorelowanymi zmiennymi przy pomocy możliwie mniejszej liczby zmiennych nieobserwowanych nazywanych czynnikami bądź faktorami, które są wzajemnie nieskorelowane.

Zmienne obserwowane są następnie modelowane jako suma odpowiednich kombinacji liniowych nowych zmiennych nieobserwowanych oraz błędu pomiaru.

W analizie czynnikowej istnieją dwa podejścia:

- eksploracyjna analiza czynnikowa (EFA, ang. exploratory factor analysis) – czynniki są początkowo nieznane i zostają wyodrębnione dzięki analizie wartości zmiennych losowych,
- konfirmacyjna analiza czynnikowa (CFA, ang. confirmatory factor analysis) – zakładamy istnienie pewnego określonego zbioru czynników i dzięki analizie wartości zmiennych losowych badamy zasadność naszego przypuszczenia i estymujemy parametry naszego modelu (modelowanie równań strukturalnych) *(Harman H., 1976).*

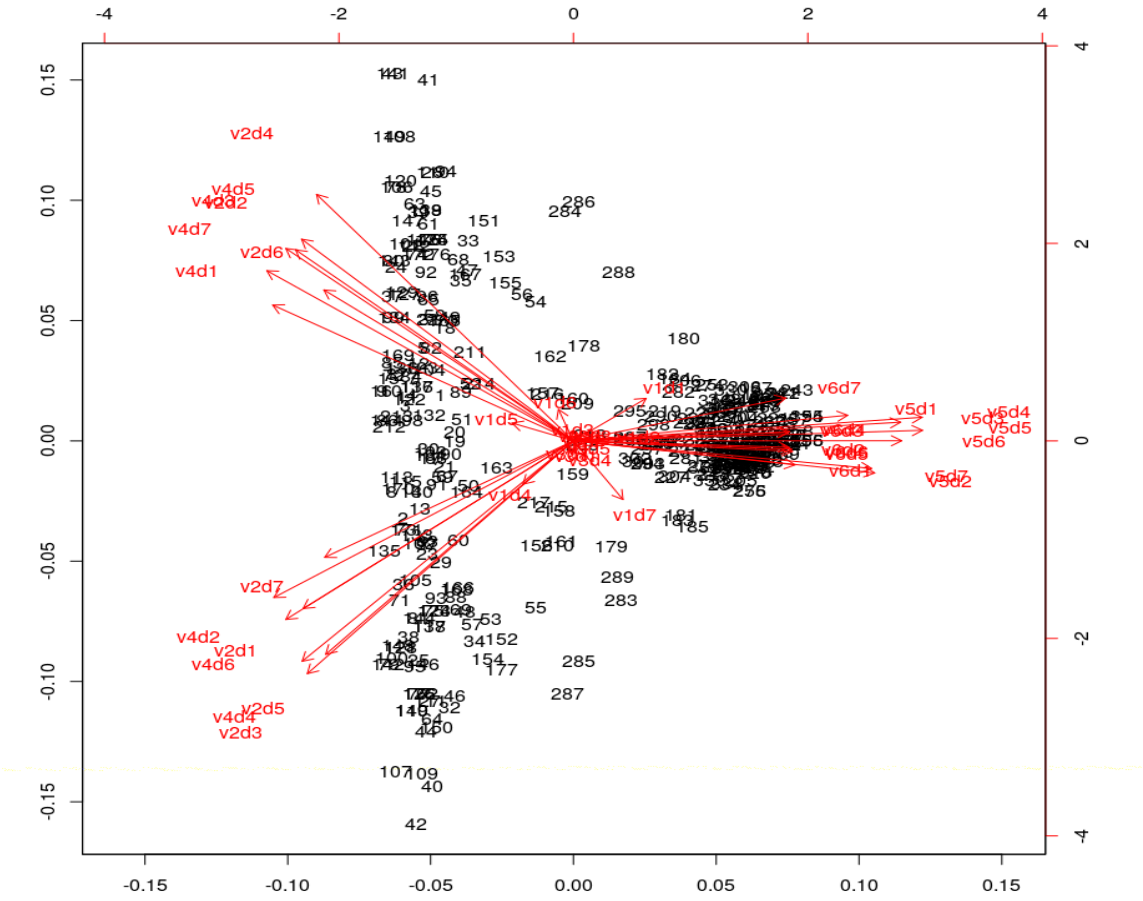
W wynikach analizy czynnikowej widzimy charakterystyczny obraz wielowymiarowej piramidy, która odzwierciedla składniki mieszaniny. Wiadomo, że mieszanina odbija się naturalnie na wykresie trójskładnikowym, ze względu na mniejszy wymiar niż liczba składników mieszaniny.



Rys. 31 Obraz wielowymiarowej piramidy wykonany analizą czynnikową.
(Źródło: opracowanie własne)

Z wykresu piargowego wynikało, że dane uzyskane w laboratorium posiadają dwa istotne kryteria (zależności). Po szczegółowej analizie autor stwierdził, że jest to podział na dni robocze i dni weekendowe. Aby potwierdzić założenie przy pomocy sieci neuronowej porównano dni tygodnia między sobą i stwierdzono, że założenie jest słuszne jednak dni z określonymi obciążeniami można podzielić na grupy. Faktem jest, że każde proste sumowanie ilości badań zleconych przez kliniki w celu uzyskanie całkowitej oceny będzie równoznaczne z przeprowadzaniem osi przez przestrzeń czynnikową, którą autor zbudował pod pewnym kątem. Jeżeli kliniki i laboratorium mocno współpracują to w ilościach i rodzajach badań będą miały miejsca powiązania, które powstają na skutek czynników współpracy poszczególnych klinik i laboratorium. Innymi słowy, siła interakcji w systemie „klinika - laboratorium" jest to długość wektora

narysowanego od początku współrzędnych do punktu na płaszczyźnie czynnikowej, odpowiadająca dziennym raportom. Na wykresie poniżej przedstawiono porównanie dni w zależności od tygodnia. Można zauważyć, że wartość V4D7 (czwarty tydzień kalendarzowy niedziela) ma diametralnie inna wartość w porównaniu do V1D7 (pierwszy tydzień kalendarzowy niedziela). Rysunek 32 jest rysunkiem wielowymiarowym przedstawionym w postaci 2D.



Rys. 32 Wykres porównujący dni w zależności od tygodnia.
(Źródło: opracowanie własne)

Przy pomocy funkcji *table(mod1$classification, wday(as.POSIXct(attr(df.bolnica.t, "dimnames")[[3]])))* zobrazowano dane uzyskane z sieci neuronowej po ugrupowaniu dni w postaci macierzy.

	1	2	3	4	5	6	7
1	53	2	0	2	2	2	52
2	0	11	12	10	10	19	0
3	0	5	5	7	5	1	0
4	0	12	11	16	16	7	0
5	0	11	19	13	11	8	0
6	0	12	5	4	8	15	0

Rys. 33 Macierz przedstawiająca podział dni tygodnia na 6 trybów pracy.
(Źródło: opracowanie własne)

Z macierzy autor wywnioskował ze istnieje 6 trybów pracy na które zostały podzielone dni:

- tryb weekendowy – 1,
- tryb przed dniem wolnym – po dniu wolnym -6,
- tryb dnia roboczego, ale nie przed weekendem -4,5,
- tryb każdego dnia, ale najczęściej przed dniem wolnym -2,
- tryb małego obciążenia, ale nie weekendowy i nie wolny – 3.

Istnieje również zależność współpracy wyznaczonych trybów. W obserwowanym okresie laboratorium przełączyło się z trybu 1, 2, 4 do trybu 1, 5, 6. Stwierdzono, że jest to znak świadomości systemu spontanicznej praktyki trybów pracy.

Korzystając z funkcji automatycznej generacji macierzy za pomocą funkcji specjalnych Matlaba wygenerowano macierz Hankela dla danych uzyskanych z jednego tygodnia. Macierz składa się z ośmiu kolumn i 357 wierszy dla tego poniżej jest przytoczony tylko część matrycy Hankela.

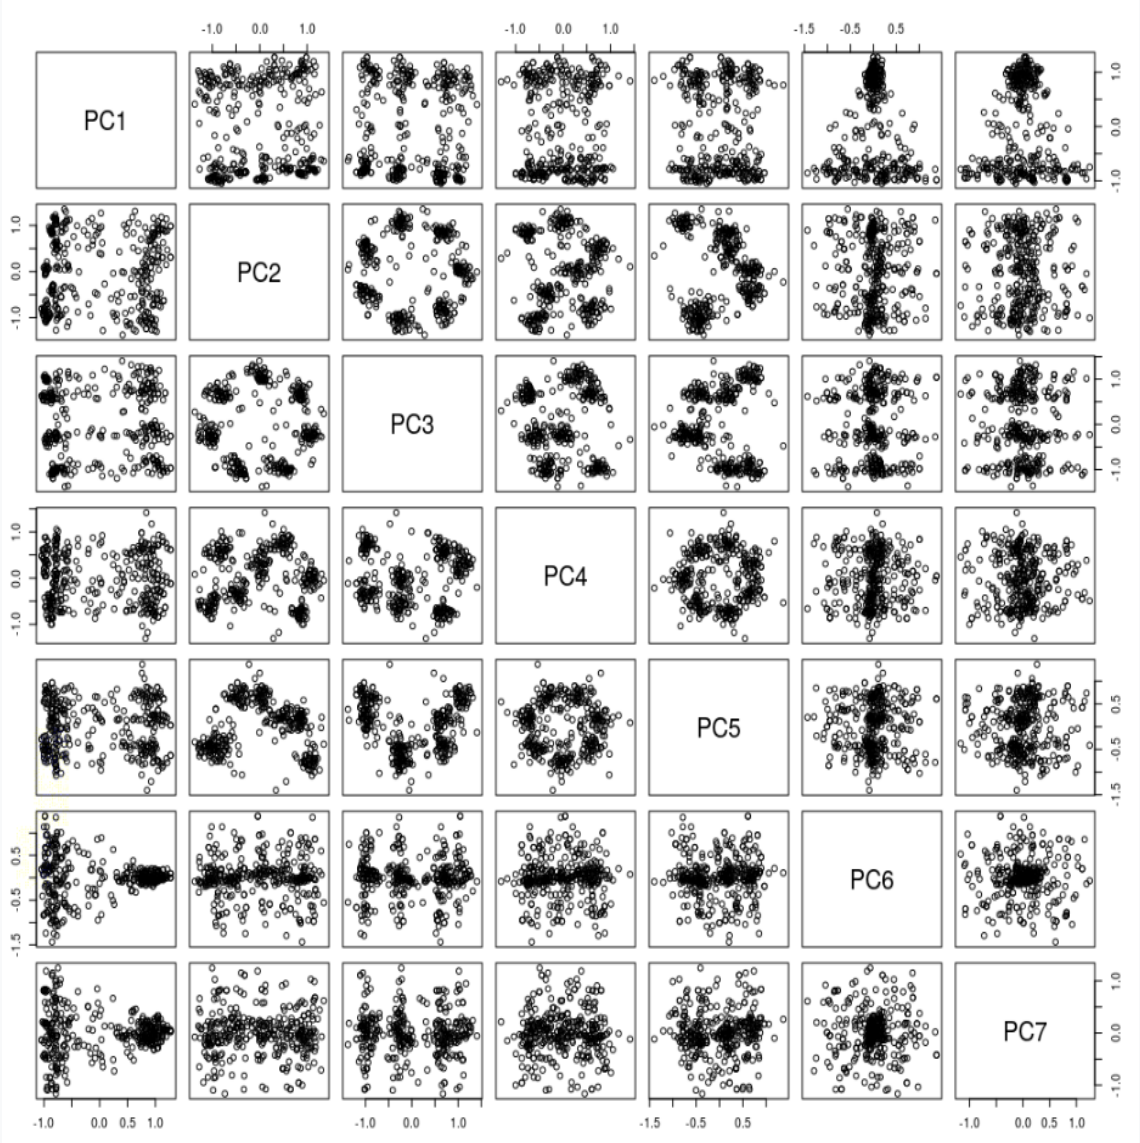
```
> hankel(mod1$classification, 7)
      [,1] [,2] [,3] [,4] [,5] [,6] [,7]
 [1,]    3    2    2    2    1    1    2
 [2,]    2    2    2    1    1    2    2
 [3,]    2    2    1    1    2    2    4
 [4,]    2    1    1    2    2    4    4
 [5,]    1    1    2    2    4    4    4
 [6,]    1    2    2    4    4    4    1
 [7,]    2    2    4    4    4    1    1
 [8,]    2    4    4    4    1    1    4
 [9,]    4    4    4    1    1    4    4
[10,]    4    4    1    1    4    4    4
[11,]    4    1    1    4    4    4    4
[12,]    1    1    4    4    4    4    4
[13,]    1    4    4    4    4    4    1
[14,]    4    4    4    4    4    1    1
[15,]    4    4    4    4    1    1    4
[16,]    4    4    4    1    1    4    4
[17,]    4    4    1    1    4    4    3
[18,]    4    1    1    4    4    3    4
[19,]    1    1    4    4    3    4    4
[20,]    1    4    4    3    4    4    1
[21,]    4    4    3    4    4    1    1
[22,]    4    3    4    4    1    1    4
[23,]    3    4    4    1    1    4    2
[24,]    4    4    1    1    4    2    4
[25,]    4    1    1    4    2    4    2
[26,]    1    1    4    2    4    2    2
[27,]    1    4    2    4    2    2    1
[28,]    4    2    4    2    2    1    1
[29,]    2    4    2    2    1    1    1
[30,]    4    2    2    1    1    1    2
[31,]    2    2    1    1    1    2    4
[32,]    2    1    1    1    2    4    2
[33,]    1    1    1    2    4    2    2
[34,]    1    1    2    4    2    2    1
[35,]    1    2    4    2    2    1    1
[36,]    2    4    2    2    1    1    2
[37,]    4    2    2    1    1    2    4
[38,]    2    2    1    1    2    4    2
[39,]    2    1    1    2    4    2    4
[40,]    1    1    2    4    2    4    2
[41,]    1    2    4    2    4    2    1
[42,]    2    4    2    4    2    1    1
[43,]    4    2    4    2    1    1    4
```

Rys. 34 Macierz Hankela dla danych uzyskanych z jednego tygodnia.
(Źródło: opracowanie własne)

Pierwsza kolumna to numer porządkowy pod którym jest zakodowane badanie. W ciągu tygodnia było zlecono przez kliniki 356 rodzajów badań, dla tego macierz Hankela składa się z 357 wierszy. Kolumny o nazwie 1, 2, 3, 4, 5, 6, 7 odpowiadają dniu tygodnia a liczby umieszczone w macierzy

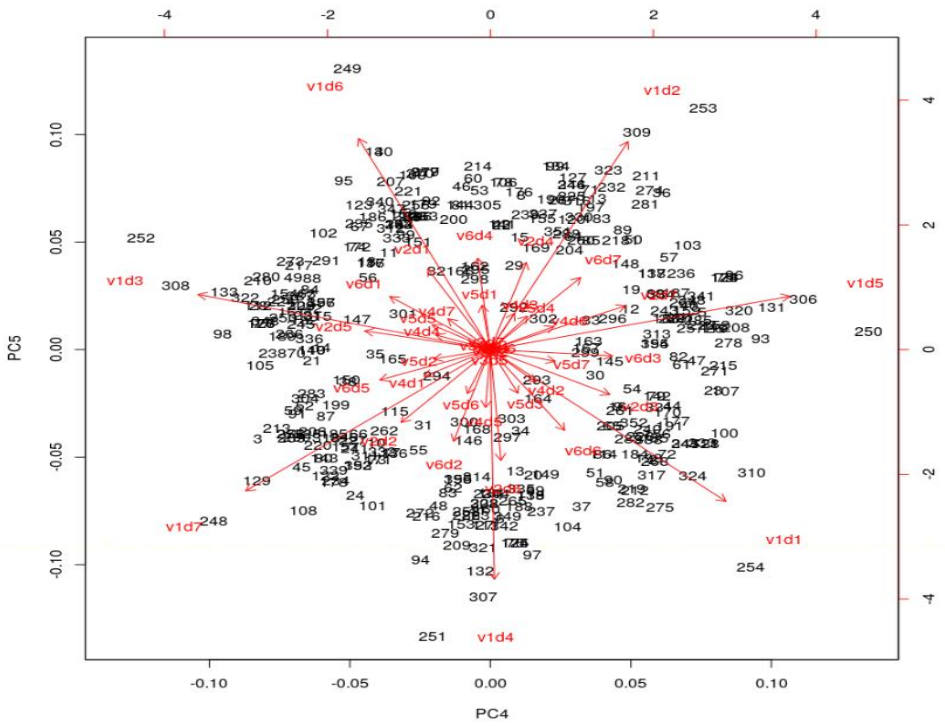
są trybami pracy laboratorium. Macierze Hankela są stosowane do minimalizacji liczby operacji arytmetycznych. Dane poukładane w postaci macierzy Hankela służą do szybkiego przewidywania losowych procesów.

Kolejnym krokiem przy tworzeniu modelu matematycznego było wykonanie analizy głównych komponentów na podstawie matrycy Hankela analizą czynnikową.

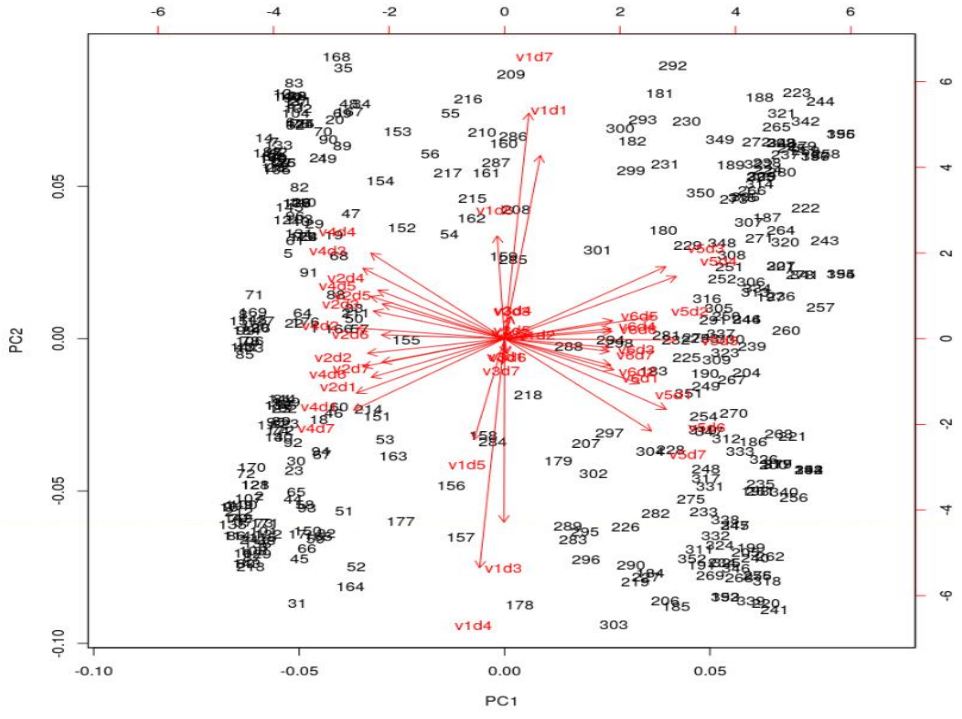


Rys. 35 Obraz wielowymiarowej piramidy wykonany analizą czynnikową dla głównych komponentów uzyskanych na podstawie matrycy. *(Źródło: opracowanie własne)*

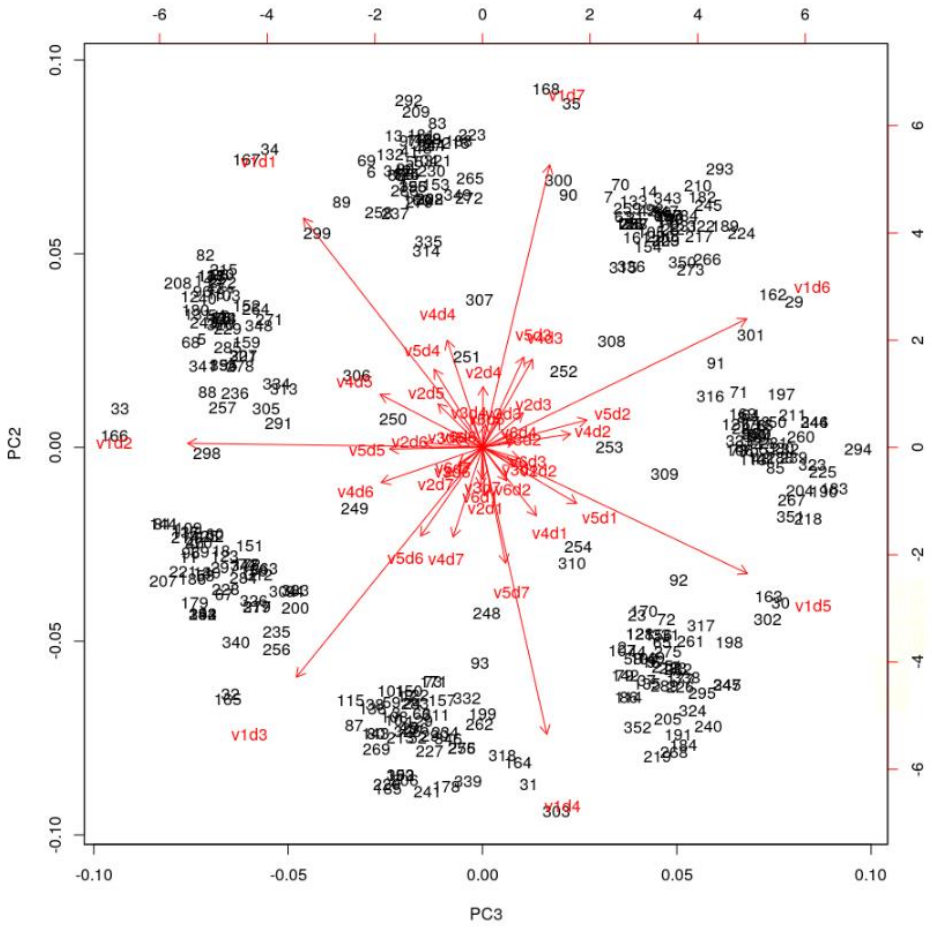
Przy pomocy sieci neuronowej wyróżniono 7 komponentów (PC1-PC7). Komponenty posiadają wspólne korelację. Poniżej są przestawione wykresy korelacji poszczególnych komponentów.



Rys. 36 Wykres korelacji komponentów PC5 i CP4. *(Źródło: opracowanie własne)*



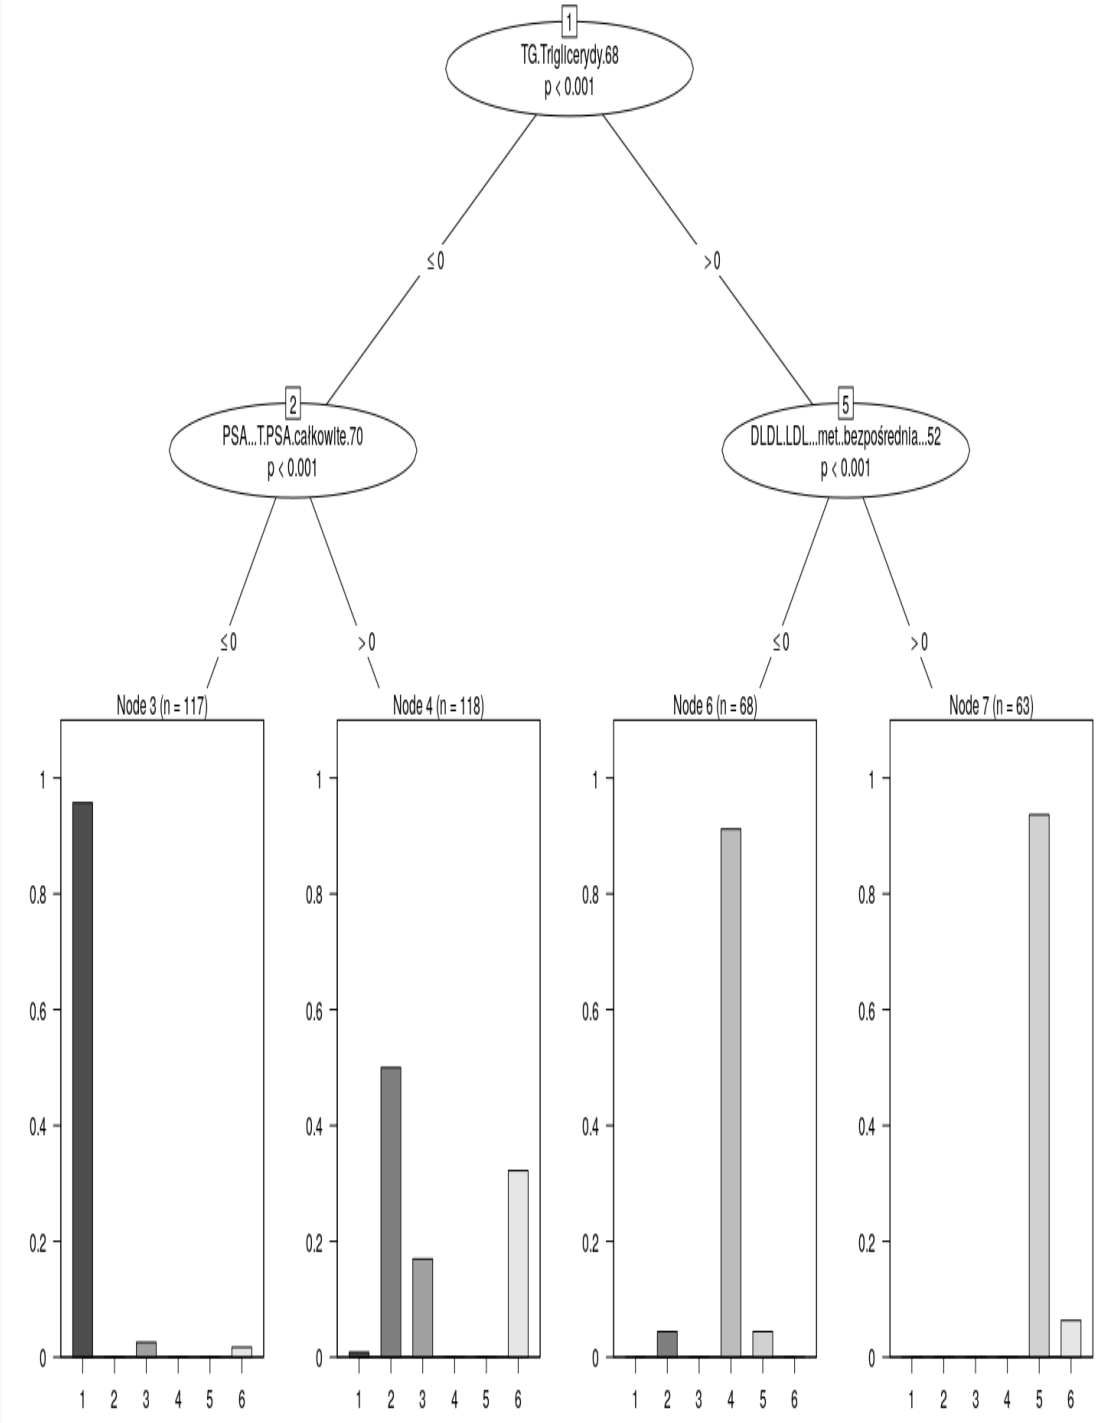
Rys. 37 Wykres korelacji komponentów PC2 i CP1. *(Źródło: opracowanie własne)*



Rys. 38 Wykres korelacji komponentów PC2 i CP3. *(Źródło: opracowanie własne)*

Rysunki 36; 37; 38 podobnie jak rysunek 32 przedstawiają powiązania, które powstają na skutek czynników współpracy poszczególnych klinik i laboratorium. Siła interakcji w systemie „klinika - laboratorium" jest to długość wektora narysowanego od początku współrzędnych do punktu na płaszczyźnie czynnikowej, odpowiadająca dziennym raportom. Na wykresach powyżej przedstawiono porównanie dni w zależności od tygodnia. Rysunki 36; 37; 38 są rysunkami wielowymiarowymi przedstawionymi w postaci 2D.

Na podstawie wyżej wymienionych zależności autor nadał ograniczenia sieci neuronowej. Zdefiniowanym zadaniem było wykonanie siecią neuronową prognozy obciążenia laboratorium w kolejnym dniu. Poniżej jest przedstawiona jedna z reguł na podstawie, której sieć neuronowa prognozuje obciążenie w zależności od rodzaju badań. Każdy rodzaj oraz ilość badań były opisane w podobny sposób. Do analizy zostały wykorzystane roczne dane obciążeń laboratorium.



Rys. 39 Jedna z reguł na której jest oparte prognozowanie sieci neuronowej.
(Źródło: opracowanie własne)

Schemat przedstawia sposób klasyfikacji dni na podstawie powiązań rodzajów badań oraz zależności dotyczących ilości zleconych badań danego rodzaju. W zależności od kombinacji mamy różne obciążenia i dni tygodnia. Jeżeli nie ma zleceń triglicerydy i nie ma zleceń PSA to wtedy to jest początek tygodnia, bo w poniedziałki te badania są rzadko wykonywane. W podobny sposób zostały sklasyfikowane pozostałe rodzaje badań.

Prognoza wiarygodności obciążenia laboratorium poszczególnymi rodzajami badań zakodowanymi numerami od 1 do 174 na kolejne dwa dni jest przedstawiona poniżej. Na rysunku 40 przedstawiona jest prognoza na dwa kolejne dni. W pierwszej kolumnie są zakodowane rodzaje badań. W drugiej i trzecie kolumnie są prognozowane ilości badań zakodowane w postaci 7 trybów pracy. Każdy tryb pracy ma w sobie zakodowane dane o minimalnej i maksymalnej ilości zleconych badań. Na rysunku 32 był przedstawiony podział na 6 trybów pracy jednak dla bardziej dokładnej prognozy tryb weekendowy który obejmował dwa dni został podzielony na dwa osobne tryby pracy.

1	6 5	46	2 1	91	6 5				
2	1 5	47	5 1	92	1 5				
3	7 2	48	4 6	93	7 6				
4	3 6	49	6 6	94	3 5	136	3 6		
5	2 1	50	1 5	95	2 1	137	2 1		
6	5 1	51	7 5	96	5 1	138	5 1		
7	4 5	52	3 6	97	7 2	139	4 6		
8	6 5	53	2 1	98	3 5	140	6 5		
9	1 5	54	5 1	99	2 2	141	1 6		
10	7 3	55	4 5	100	5 4	142	7 5		
11	3 6	56	6 5	101	4 5	143	3 6		
12	2 1	57	1 5	102	2 1	144	2 1		
13	5 1	58	7 5	103	5 1	145	5 1		
14	4 5	59	3 6	104	4 5	146	4 6		
15	6 5	60	2 1	105	6 5	147	6 6		
16	1 5	61	5 1	106	1 3	148	1 6		
17	7 5	62	4 6	107	2 1	149	7 5		
18	3 5	63	6 5	108	5 1	150	3 6		
19	2 1	64	1 1	109	2 1	151	2 1		
20	5 1	65	7 6	110	5 1	152	5 1		
21	4 6	66	3 5	111	4 6	153	4 6		
22	6 5	67	2 1	112	6 6	154	6 5		
23	1 6	68	5 1	113	1 3	155	1 5		
24	7 5	69	4 6	114	7 3	156	7 5		
25	3 6	70	6 5	115	3 1	157	3 6		
26	2 1	71	1 5	116	2 1	158	2 1		
27	5 1	72	7 5	117	5 1	159	5 1		
28	6 5	73	3 5	118	4 5	160	4 6		
29	1 5	74	2 1	119	6 5	161	6 5		
30	7 6	75	5 1	120	1 1	162	1 6		
31	3 6	76	4 5	121	7 5	163	7 3		
32	2 1	77	6 6	122	3 6	164	3 6		
33	5 1	78	1 5	123	2 1	165	2 1		
34	4 5	79	7 6	124	5 1	166	5 1		
35	6 5	80	3 6	125	4 5	167	4 5		
36	1 5	81	2 1	126	6 6	168	6 5		
37	7 6	82	5 1	127	1 3	169	1 5		
38	3 6	83	4 5	128	7 5	170	7 5		
39	2 1	84	6 5	129	3 5	171	3 5		
40	5 1	85	1 3	130	2 1	172	2 1		
41	6 3	86	7 6	131	5 1	173	5 1		
42	1 3	87	3 5	132	4 6	174	4 6		
43	7 5	88	2 1	133	6 5				
44	3 6	89	5 1	134	1 5				
45	3 6	90	4 6	135	7 6				

Rys. 40 Prognoza wiarygodności obciążenia laboratorium na kolejne dwa dni.
(Źródło: opracowanie własne)

11. PRZETESTOWANIE WYNIKÓW PROGNOZY W BADANYM PODMIOCIE GOSPODARCZYM

Dane zaproponowane przez sieć neuronową jako obciążenie na dwa kolejne dni zostały porównane z fizycznymi danymi które uzyskano w tych dniach w laboratorium na podstawie raportów. Porównując dane średni błąd prognozy wyniósł 3,95 %. Warto zauważyć, że podczas stworzenia modelu prognozującego obciążenia autor próbował ograniczyć się danymi uzyskanymi w ciągu jednego miesiąca i na podstawie tych danych opisać reguły i zależności. W przypadku gdy sieć neuronowa korzystała z danych uzyskanych w ciągu jednego miesiąca średni błąd prognozy wyniósł 5,52 %. Można założyć, że jeżeli autor posiadałby więcej danych (np. z 24 lub 36 miesięcy) sieć neuronowa wyszukałaby inne rzadkie zależności i wtedy udałoby się zminimalizować średni błąd prognozy. Przeprowadzone obliczenia potwierdziły dużą przydatność sztucznych sieci neuronowych do prognozowania obciążeń.

12. ZASTOSOWANIE MODELU MATEMATYCZNEGO W PRZEDSIĘBIORSTWIE PRODUKCYJNYM

Do testowania modelu matematycznego wybrano przedsiębiorstwo produkcyjne BAS Sp. z o. o. Przedsiębiorstwo Belma accessories systems to firma specjalizująca się w kompleksowej obróbce blach. Już od momentu powstania pomysłu projektu, kompleksowo wspiera klientów, zarówno w doradztwie technicznym, jak i projektowym. Przygotowuje wzorce, by następnie tworzyć pierwsze partie produkcyjne oraz złożone projekty dla różnych branż.

Chcąc sprostać wysokim aspiracjom i wymaganiom partnerów biznesowych z całego świata, przedsiębiorstwo nieustannie się rozwija, inwestując w nowoczesny park maszynowy, zasoby ludzkie, a także powiększa powierzchnię przemysłową, magazynową i socjalną. Obecnie

Belma accessories systems zatrudnia ponad 800 osób w zakładzie o powierzchni 32 200 m^2.

Firma ma m.in. możliwość wykrawania laserowo i combi laserowo - CNC, wykrawania z kręgu, gięcia. Posiada zrobotyzowane stanowiska spawalnicze, linie produkcyjne i malowania proszkowego oraz proponuje bogatą gamę usług w zakresie uszlachetniania blach.
Belma AS posiada doświadczenie w realizacji zarówno krótkich partii produkcyjnych, jak i zamówień wielkoseryjnych.
System, oparty między innymi o normy ISO 9001 i ISO 14001, zapewnia usługi na najwyższym poziomie produkcyjnym, jakościowym oraz gwarantuje szeroki wachlarz rozwiązań logistycznych. Wszystkie etapy realizacji produktu wykonywane są z troską o środowisko naturalne.
Belma accessories systems jest producentem wyrobów z blachy o różnym stopniu skomplikowania poczynając od prostych szafek elektrycznych, poprzez szafy telekomunikacyjne do bardzo zaawansowanych technologicznie szaf energetycznych dla elektrowni wiatrowych i słonecznych. Zgodnie z życzeniami klientów Belma AS wyposaża produkowane wyroby w niezbędne komponenty.
Zintegrowany system MRP II wdrożony w 2008 roku pomaga w terminowej obsłudze i realizacji ponad 65 000 zleceń produkcyjnych rocznie. Pełną kontrolę stopnia zaawansowania i terminowej realizacji produkcji umożliwia system rejestracji wszystkich wykonywanych operacji za pomocą kodów kreskowych. Rocznie Belma AS przetwarza 7 500 ton blachy, z której produkuje ponad 4 500 000 części potrzebnych do zrealizowania zleconych projektów. Zabezpieczenie antykorozyjne i walory estetyczne wyprodukowanych wyrobów Belma accessories systems uzyskuje malując proszkowo detale o łącznej powierzchni 1 200 000 m^2, zużywając do tego celu 200 ton farb rocznie. Montaż finalny odbywa się na trzech halach o łącznej powierzchni 7 000 m^2 z możliwością rozbudowy (na każdej hali realizowane są innego typy projekty i wyroby).

Do przetestowania algorytmu wybrano dwa bezpośrednio współpracujące działy wykrawania oraz gięcia detali. Na obszarze wykrawania znajduje się:

- cztery wykrawarki laserowe,
- jedna wykrawarka laserowo-rewolwerowa,

- osiem wykrawarek rewolwerowych.

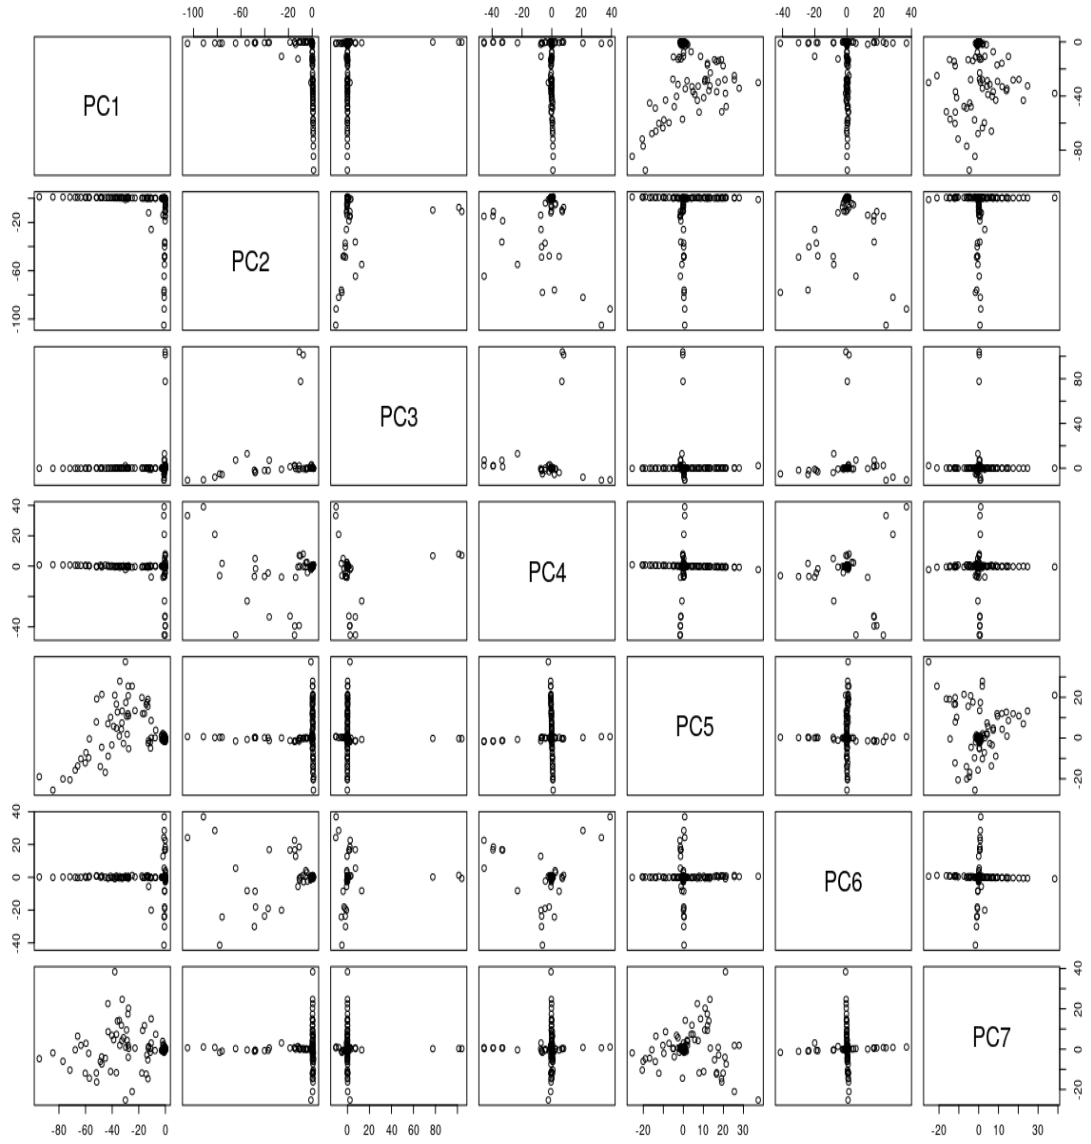
Na obszarze gięcia znajduje się:

- siedem pras krawędziowych EHT,
- trzy prasy krawędziowe Prima,
- osiem pras krawędziowych Bystronic .

Obszary obejmuje trzyzmianowy tryb pracy. Dane na podstawie których był testowany model matematyczny były uzyskane z okresu dwóch miesięcy. W tym okresie na dwóch obszarach wykonano 9 281 operację co się przekłada na 4 882 zlecenia.

Przed rozpoczęciem testowania modelu matematycznego podobnie jak i w przypadku laboratorium dane były sprecyzowane, wyczyszczone, doprowadzone do postaci, którą może wykorzystać sieć neuronowa. Podobnie jak w przypadku z laboratorium głównym zadaniem było wykonanie analizy głównych komponentów na podstawie matrycy Hankela. Przy pomocy sieci neuronowej wyróżniono 7 komponentów. W odróżnieniu od danych uzyskanych podczas analizy laboratorium w analizowanym przedsiębiorstwie produkcyjnym nie wszystkie komponenty posiadają wspólną korelację. Można to uzasadnić różnicami w organizacji pracy oraz specyfiką branży, w której działają podmioty gospodarcze. Poniżej są przestawione wykresy korelacji poszczególnych komponentów.

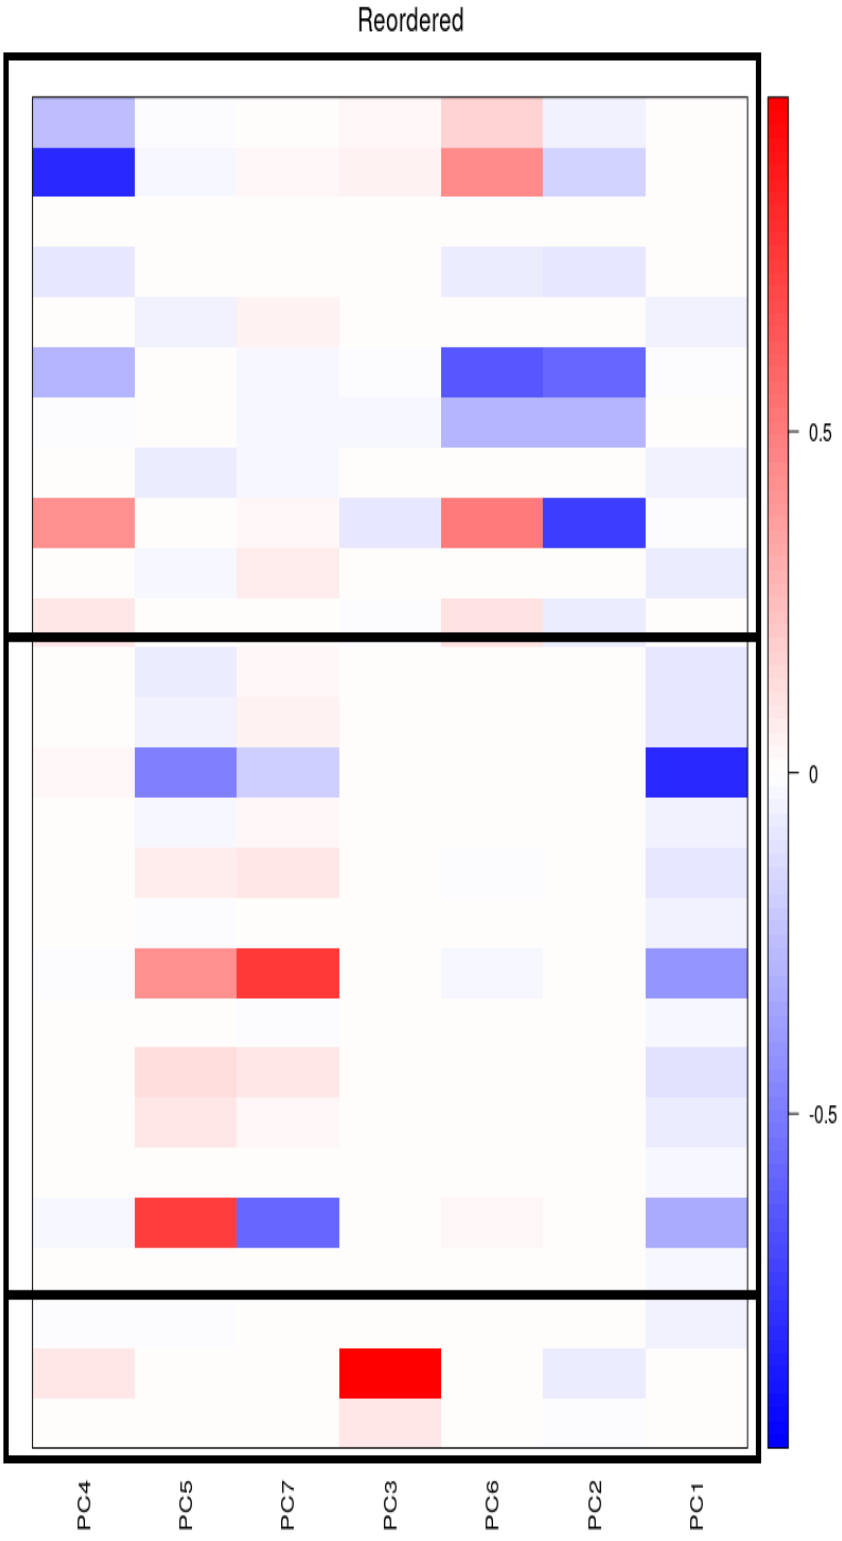
Analizując wykres na rysunku 41 można stwierdzić że komponent PC1 koreluje tylko z komponentem PC5 oraz PC7. Komponent PC2 ma słabą korelację z PC4 oraz PC6. Można uznać że Komponent PC3 nie ma korelacji z innymi komponentami. PC4 koreluje z PC2 i PC6 jednak te korelacje są słabe. komponent PC5 ma korelacje z PC1 i PC7. Komponent PC6 ma korelacje z PC2 i PC4. Ostatni komponent PC7 koreluje z PC1 i PC5. Najbardziej zauważalna korelacja jest pomiędzy komponentami PC1, PC5, PC7. Interpretując ten wykres innymi słowami sieć neuronowa wyróżniła siedem wspólnych cech łączących ludzi i maszyny – siedem cech zawodowych



Rys. 41 Obraz wielowymiarowej piramidy wykonany analizą czynnikową dla głównych komponentów uzyskanych na podstawie matrycy dla przedsiębiorstwa produkcyjnego. *(Źródło: opracowanie własne)*

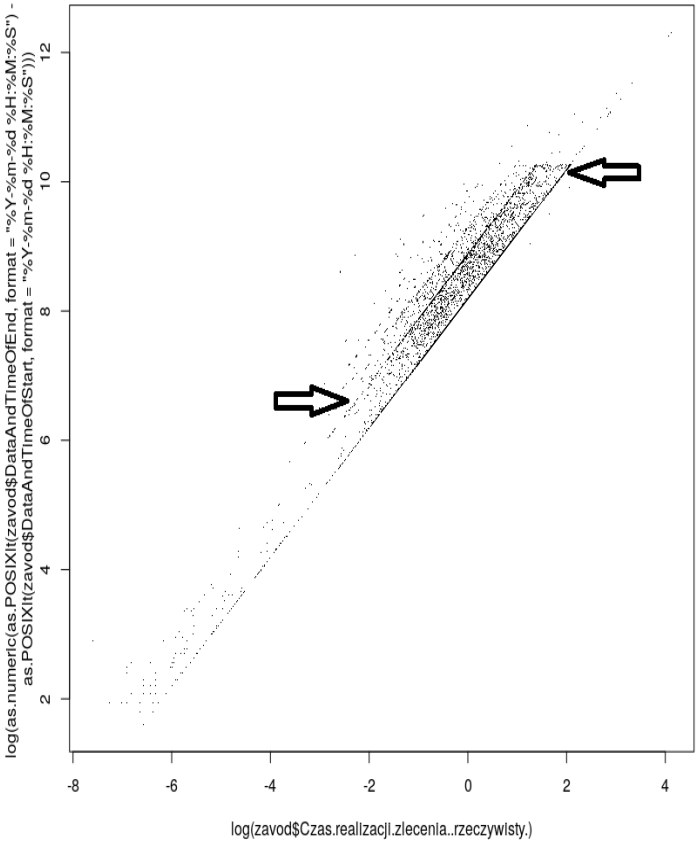
.

Analizując dane dotyczące ilości wykonywanych zleceń oraz pracochłonności sieć neuronowa podzieliła maszyny na 3 grupy. Wykres przedstawiony poniżej wizualizuje te grupy. Kolor na rysunkach to tylko jakieś znaczenie nadane przez sieć.



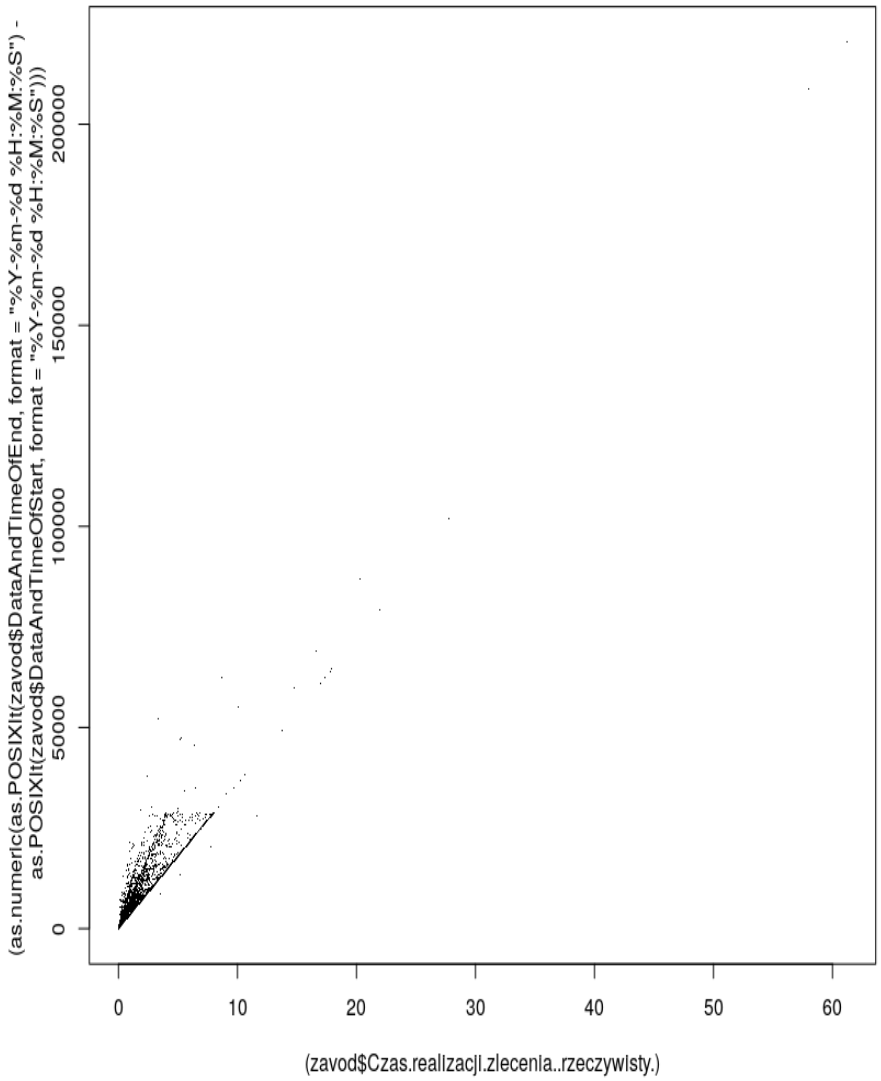
Rys. 42 Podział maszyn na 3 grupy. *(Źródło: opracowanie własne)*

Interpretując ten wykres zaczynając od dołu jest to grupa maszyn wykrawających, następnie największy obszar zajmują prasy krawędziowe, górny obszar to grupa maszyn wykrawających technologią palenia (lasery oraz combi).
Analizowane przedsiębiorstwo ma stałych klientów oraz podpisane umowy w horyzoncie kilkuletnim, posiada również dział planowania i sterowania produkcją które równomiernie obciążają maszyny i ludzi. W tym przypadku nie ma większego sensu szukać różnorodność w dniach tygodnia pod względem obciążeń, nie ma dużej ilości działów które zlecają różnorodne zlecenia. Nie ma stanowisk, które można zaliczyć do wąskiego gardła. Dla tego w kolejnych krokach analizy skupiono się na rytmiczności pracy. Jak duży wpływ ma czynnik ludzi, jakie są szanse awarii maszyny lub brak wykonania normy w przypadku połączenia operatora x i maszyny y. Ze względu na dużą liczbę maszyn i trzyzmianowy tryb pracy oraz różne doświadczenie, kompetencje i szkolenia operatorów istnieje duża liczba kombinacji połączeń operatorów i maszyn. Przy pomocy sieci neuronowej na podstawie danych uzyskanych z przedsiębiorstwa można skomponować zmianę z najlepszymi operatorami lub ustawić operatorów maszyn na określone stanowiska zwiększając efektywność pracy lub zmniejszając ryzyko powstania awarii lub braków. Aby potwierdzić założenia, że przedsiębiorstwo posiada awarie i że operatorzy maszyn nie zawsze mieszczą się w normach czasu przypisanych do zleconych zadań, na podstawie danych uzyskanych w przedsiębiorstwie dotyczących zakładanego czasu realizacji zleceń i faktycznego czasu realizacji zlecenia autor stworzył wykres liniowy który odzwierciedla sytuacje w przedsiębiorstwie.



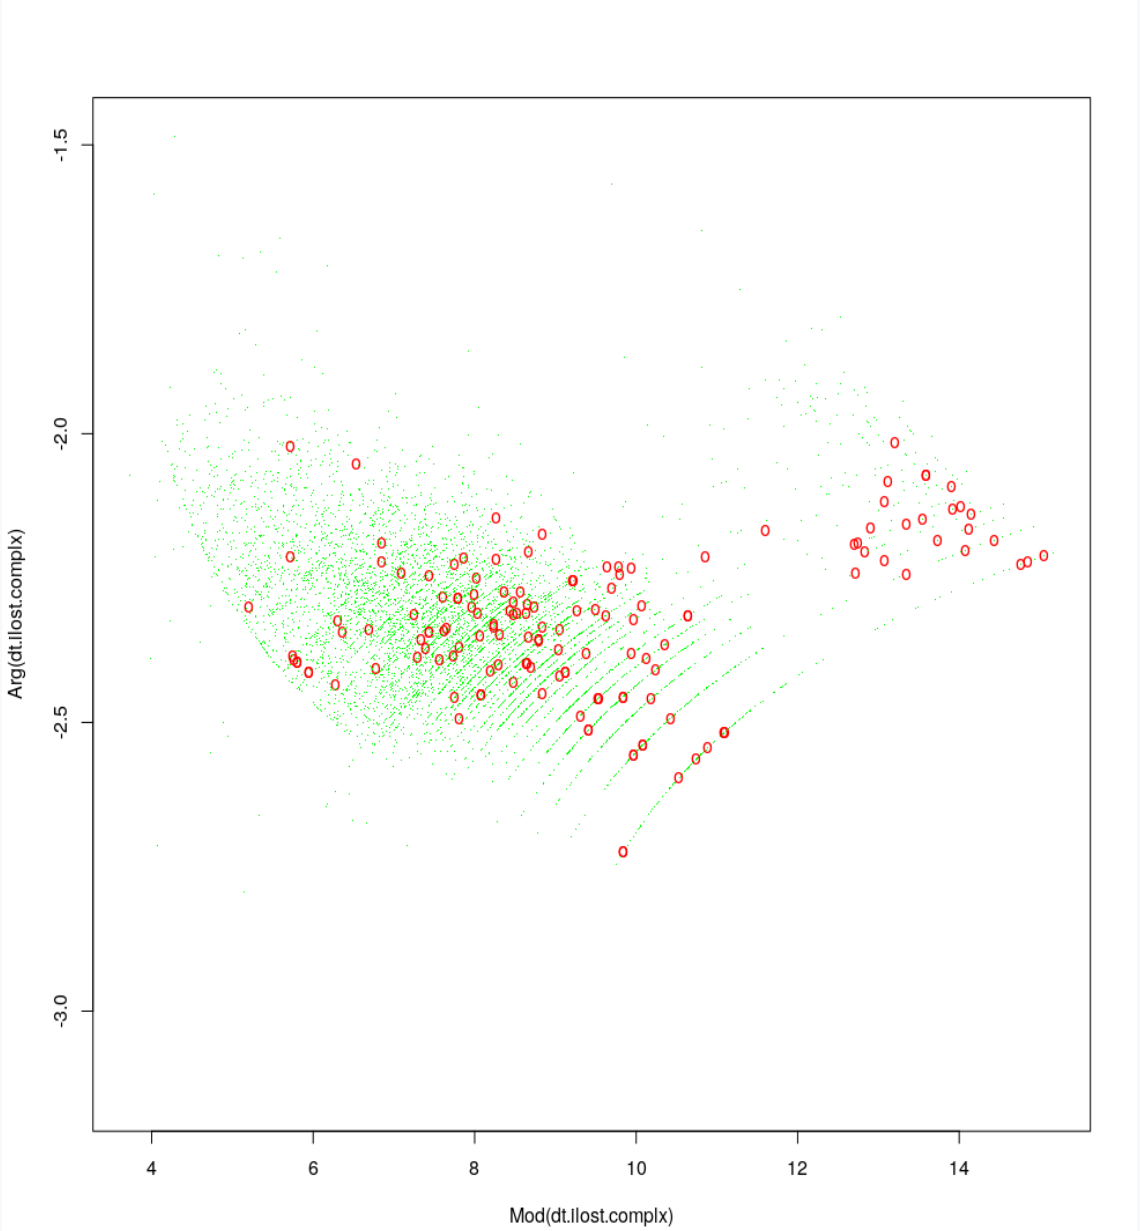
Rys. 43 Porównanie zakładanego czasu pracy i rzeczywistego.
(Źródło: opracowanie własne)

Linie zaznaczone strzałkami jest to zakres zakładanego czasu realizacji zleceń. Punkty umieszczone nad drugą linią oznaczają przypadki kiedy operator nie wyrobił się ze zleceniem w zakładanym czasie. W uzyskanych danych z przedsiębiorstwa nie ma informacji z jakiego powodu operator nie wykonał normy przypisanej do zadania. Jednak analizując jednego wytypowanego operatora oraz zlecenia, gdzie wytypowany operator nie miał zakładanej efektywności pracy i stanowiska na których wykonywał te zlecenie można znaleźć zależności które są związane kompetencjami operatora oraz z poziomem trudności wykonywanego detalu. Poniżej przedstawiono dane z poprzedniego wykresu w postaci wyników rozłożonych funkcją PCA angle tworząc radar. Rysunek przedstawia ¼ radaru. Środek współrzędnych to idealny wynik.



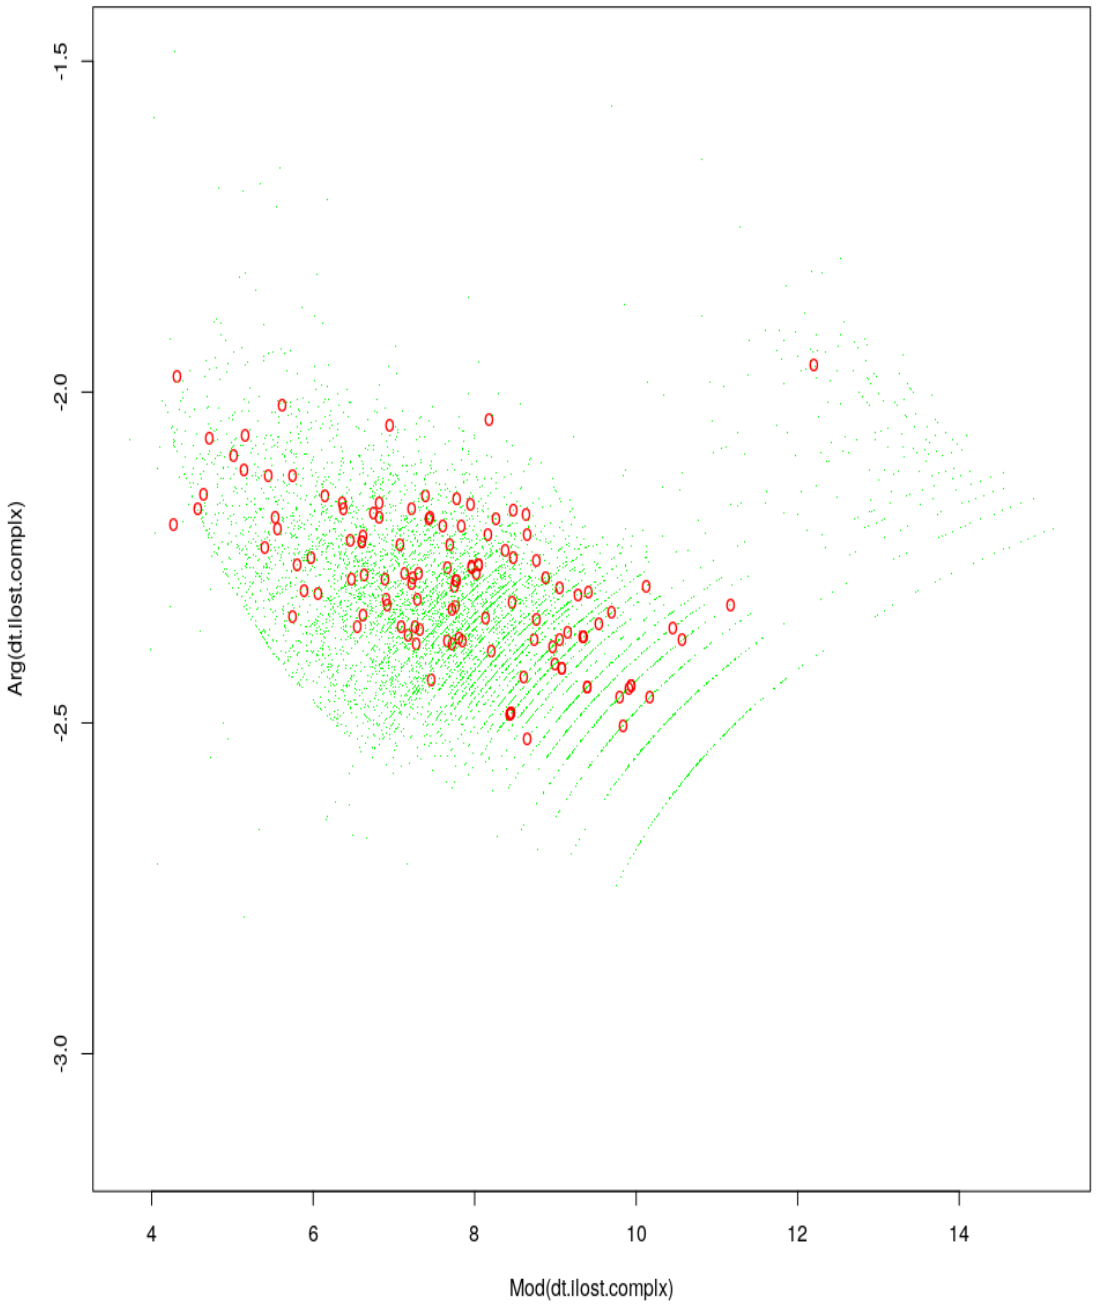
Rys. 44 Porównanie zakładanego czasu pracy i rzeczywistego rozłożonych funkcją PCA angle. *(Źródło: opracowanie własne)*

Większość zleceń jest wykonanych w założonym czasie jednak jest spora ilość zleceń które przekraczają ten czas. Jest to potwierdzenie założenia, że przedsiebiorsto nie jest idealne i że przy pomocy sieci neuronowej można wropwadzić ulepszenia które pozwolą zwiększyc rytmiczność pracy.
Kolejnym krokiem analizy przedsiębiorstwa produkcyjnego było wytypowanie dowolnego operatora i porównanie go z resztą osób. Wygenerowano wykres, który przedstawia taka zależność.



Rys. 45 Porównanie wyników pracy jednego operatora w stosunku do reszty osób.
(Źródło: opracowanie własne)

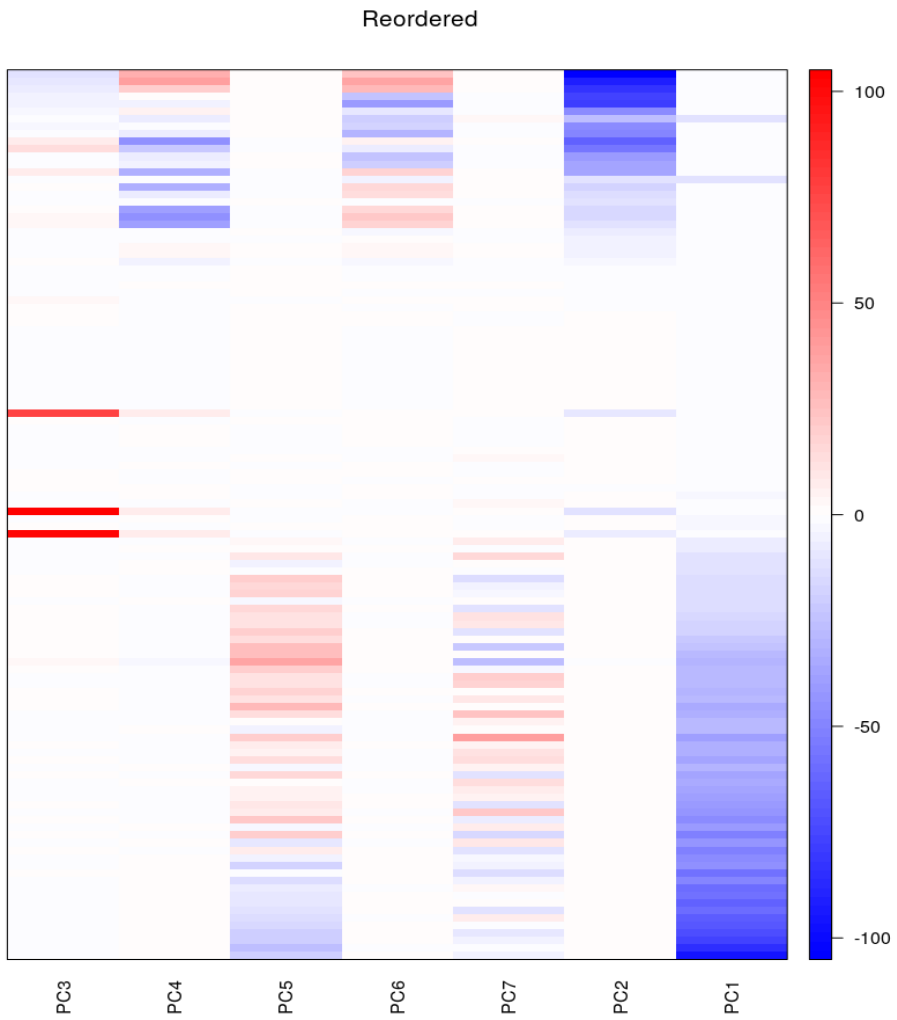
Czerwonym kolorem sa zaznaczone wyniki wyrobienia wytypowanej osoby, zielonym kolorem są oznaczone wyniki wyrobienia pozostałych operatorów. Aby móc łatwiej wywnioskować, czy wytypowany operator mieści się w czołówce najlepiej pracujących operatorów, czy też ma pośrednie wyniki, zastosoawno funkcję PCA angle która tworzy radar. Rysunek przedstawia ¼ radaru. Początek układu współrzędnych to idealny wynik.



Rys. 46 Porównanie wyników pracy jednego operatora w stosunku do reszty osób rozłożonych funkcją PCA angle. *(Źródło: opracowanie własne)*

W tym przypadku górny lewy róg pełni rolę idealnych wyników dla operatora. Posiadając teego rodzaju narzędzia z łatwościa można podzielic operatórów na grupy pod względem doswiadczenia, efektywności pracy itd.

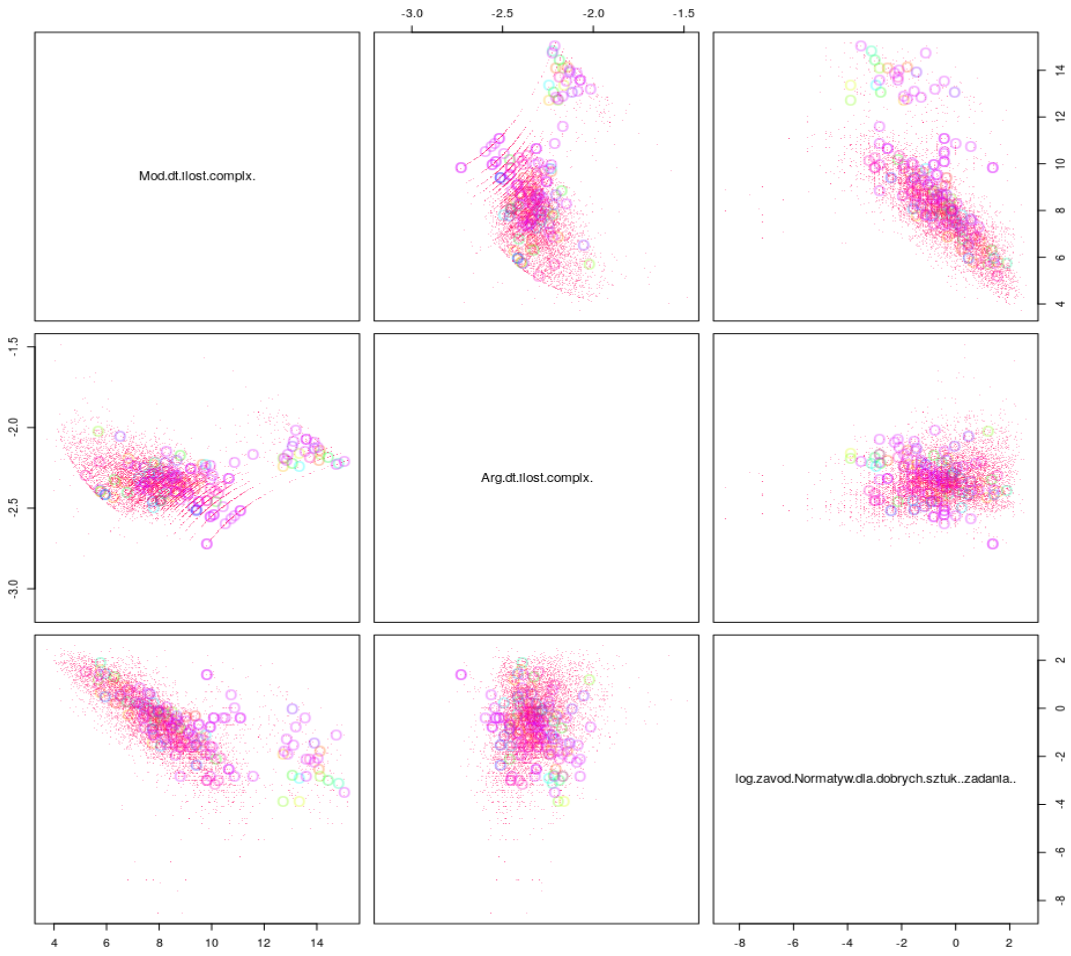
Poniżej jest przedstawiony wykres z podziałem operatorów na grupy. Wykres powstał na podstawie zalezności które znalazła sieć neuronowa korzytsjąc z 7 komponentów które maja największy wpływ na produkcję oraz porównanie tych komponentów z wynikami poszczególnych operatorów.



Rys. 47 Podział operatorów na 3 grupy. *(Źródło: opracowanie własne)*

Z wykresu wynika, że najwięcej jest operatorow o średnich wynikach. Drugą pozycję pod względem liczebności zajmują osoby o wysokich kompetencjach z dobrymi wynikami. Trzecia najmiejsza stanowi grupa operatorów posiadających małe doświadczenie.
Przyjmując założenie, że zlecenie, które trwa najdłużej i składa się z niedużej ilości detali jest skomplikowane, jak również posiadając

informacje na której maszynie były wykonane zlecenie autor stworzył wykres, który pzedstawia maszyny na których są najczęściej wykonywane skomplikowane detale i z jaką efektywnością.

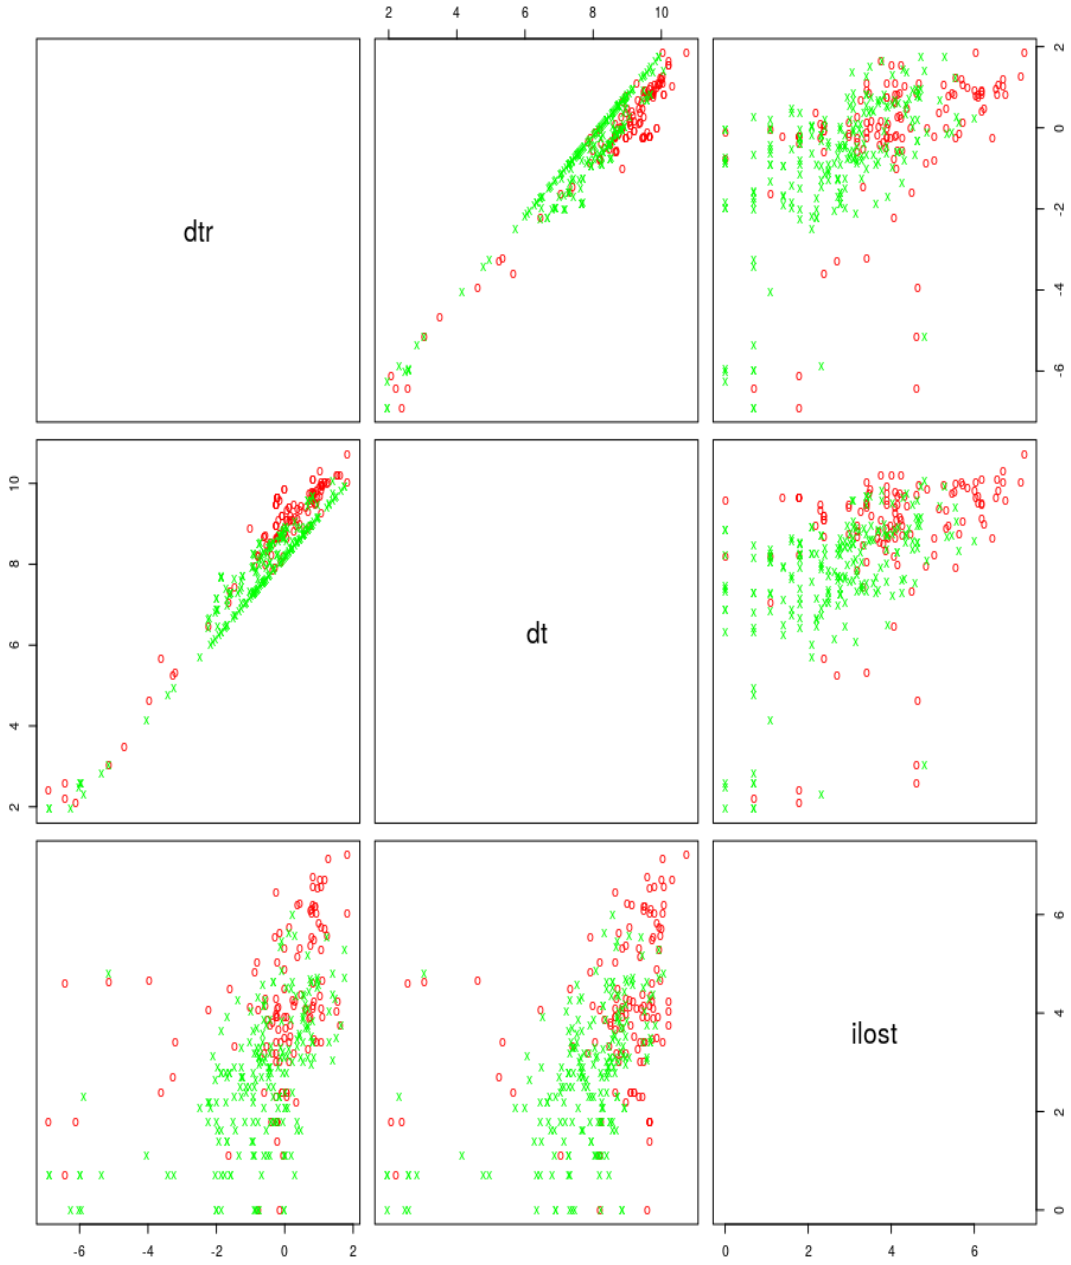


Rys. 48 Wykres przedstawia maszyny, które są najczęsciej używane do skomplikowanych zleceń. *(Źródło: opracowanie własne)*

Wykres przedstawia maszyny, które są najczęściej używane do skomplikowanych zleceń. Różne kolory oznaczają różne maszyny. Analizując wyniki oraz wykres można stwierdzić, że najwięcej zleceń jest wykonywanych na dwóch grupach maszyn maszynach (czerwone i fioletowe krążki).

Posiadając pełen obraz zależności, które istnieją w firmie przy pomocy sieci neuronowej została przeanalizowana pierwsza zmiana. Zadaniem sieci

neuronowej było wytypowanie operatora, który wykonując skomplikowany detal na wcześniej wymienionych maszynach (czerwone i fioletowe krążki) miał realizację procesu najbardziej zbliżoną do idealu. Poniżej jest przedstawiony wykres najlepszego pracownika (czerwone krążki) pod względem wyrobienia w porównaniu do reszty zmiany.



Rys. 49 Wykres przedstawia najlepszego pracownika pod względem efektywności w porównaniu do reszty zmiany. *(Źródło: opracowanie własne)*

DTR oznacza zakładany czas realizacji zlecenia przez technologa. DT oznacza rzeczywisty czas realizacji zlecenia. Z wykresu widać, że rzeczywisty czas realizacji wytypowanego przez sieć neuronową operatora był w większości przypadków mniejszy w porównaniu do zakładanego czasu w procesie produkcyjnym. Zastosowany model matematyczny posiada dużo innych możliwości które mogą wnosić wartość dodaną dla przedsiębiorstwa.

W analogiczny sposób algorytm był przetestowany w przedsiębiorstwach produkcyjnych Krusz-Tech oraz Rezmet.

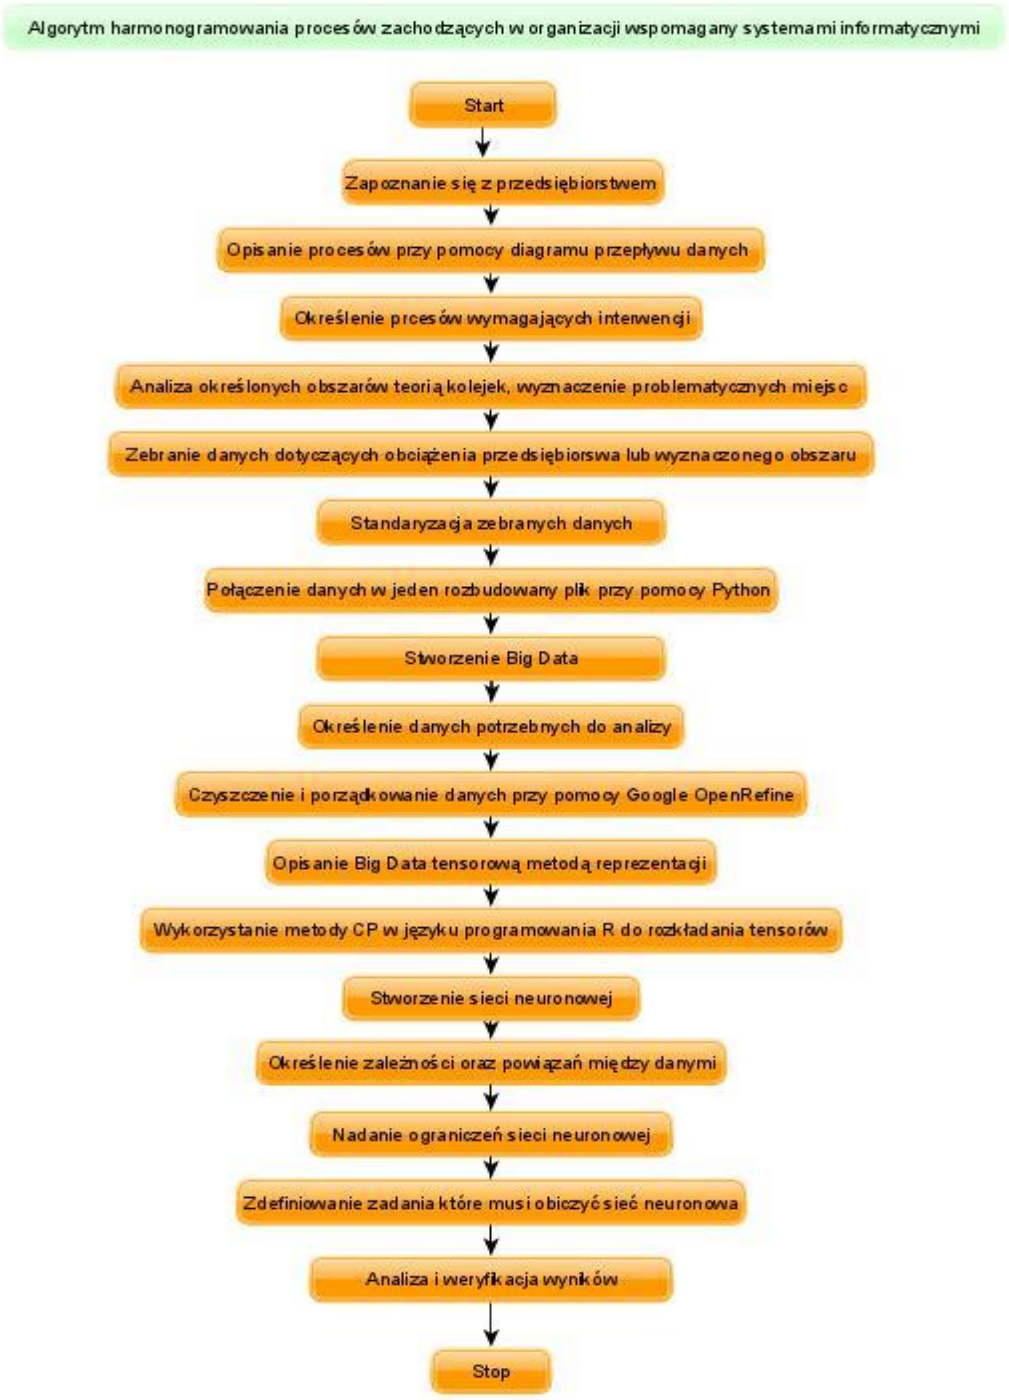
13. ALGORYTM HARMONOGRAMOWANIA PROCESÓW

W poniższym rozdziale autor podsumował działania, które zostały wykonane w pracy doktorskiej i opisał to w postaci algorytmu. Algorytm to skończony ciąg jasno zdefiniowanych czynności koniecznych do wykonania pewnego rodzaju zadań, sposób postępowania prowadzący do rozwiązania problemu *(Gershenfeld N., 1998).* Celami szczegółowymi które w przypadku algorytmu można nazwać problemem było:

- Stworzenie modelu umożliwiającego prognozowanie obciążenia na kolejne dni.

- Identyfikację powiązań pomiędzy warunkami eksploatacji i doskonaleniem systemu zarządzania warunkami pracy.

- Stworzenie modelu optymalizacji procesów zachodzących w przedsiębiorstwie, opartego na teorii kolejek i diagramie przepływu danych pozwalających uzyskać rytmiczność pracy.



Rys. 50 Schemat przedstawia algorytm harmonogramowania procesów zachodzących w organizacji wspomagany systemami informatycznymi. *(Źródło: opracowanie własne)*

Działania wykonane przez autora w trakcje przygotowania danych oraz w trakcje badań i analizy zostały opisane jako zadania w postaci graficznej i są przedstawione na rysunku 50.

14. ZASTOSOWANIE MODELU W WARUNKACH PRZEMYSŁOWYCH

Opracowany przez autora pracy algorytm zawiera elementy sztucznej inteligencji. Sztuczna inteligencja szybko znajduje swoje miejsce w kluczowych obszarach działalności przedsiębiorstw w tym w przedsiębiorstwach produkcyjnych. Sztuczna inteligencja, która ludzką inteligencję rozszerza o efektywne przetwarzanie i precyzyjną analizę danych, umożliwia podejmowanie lepiej umotywowanych decyzji, natomiast automatyzacja usprawnia działania. Trzy czynniki przyczyniły się do rozwoju tych nowych technologii. Pierwszym z nich jest chmura, która zapewniała dostęp do dużej mocy obliczeniowej na żądanie. Drugi to rosnąca liczba danych, które przekroczyły masę krytyczną i wymagają zastosowania inteligentnych algorytmów, które są podstawą sztucznej inteligencji i automatyzacji. Trzecim czynnikiem są nowe narzędzia, które firma może łatwo wdrożyć i zintegrować ze środowiskiem IT. Zastosowanie opracowanego przez autora algorytmu w przedsiębiorstwie będzie miało wpływ na:

- Osiąganie wymiernych korzyści w oparciu o dane. Dane mają ogromne znaczenie, a potrzebne informacje muszą być dostępne w czasie rzeczywistym. Gdy zbiory danych stają się coraz większe, nowe, zautomatyzowane narzędzia oparte na sztucznej inteligencji umożliwiają wykorzystanie uzyskanych w ten sposób informacji do podjęcia odpowiednich działań. Reasumując zastosowanie algorytmu w przedsiębiorstwie produkcyjnym pozwala na szybką analizę i podejmowanie znaczących decyzji.

- Doskonalenie działań operacyjnych. Chmura upraszcza wiele procesów, ale na niektórych obszarach wprowadza dodatkowy wymiar, co informatykom utrudnia optymalizację i zapobieganie awariom. Sztuczna inteligencja może zautomatyzować wiele zadań związanych z monitorowaniem i kontrolą, które są niezbędne do zapewnienia efektywnej pracy systemu. Zastosowanie algorytmu

opracowanego przez autora może być zastosowany do przewidywania awarii.

- Zwiększenie wydajności przedsiębiorstwa. Opracowany algorytm przetestowany danymi uzyskanymi w przedsiębiorstwie produkcyjnym BAS Sp. z o.o. potwierdza możliwość analizowania efektywności pracy oraz komponowanie najbardziej wydajnych zespołów pracowników jak również optymalny dobór stanowisk pracy.

- Rytmiczność pracy. Stabilizacja obciążenia oraz rytmiczność pracy zasobów ludzkich przedsiębiorstwa zwiększa efektywność wykorzystania parku maszynowego, zmniejsza ilość popełnianych błędów, zmniejsza robociznę bezpośrednią oraz zwiększa oszczędność czasu. Algorytm opracowany w niniejszej pracy pozwala na określenie problematycznych stanowisk które wymagają usprawnień.

- Prognozowanie obciążeń. Algorytm posiada możliwość prognozowania obciążeń na kolejne dni. Jednak ta funkcjonalność może być stosowana efektywnie tylko w przypadku przedsiębiorstw które nie posiadają umów długoterminowych na wykonanie wyrobów i zaplanowanych zleceń.

- Efektywność zarządzania kapitałem ludzkim. Pomiar efektywności kapitału ludzkiego należy do największych wyzwań współczesnego zarządzania. Wynika to z samej natury tego kapitału. Kapitał ludzki jest czymś więcej niż zasoby ludzkie. Kapitał ludzki jest kategorią dynamiczną, a także jakościową, pozwalającą na realizację tworzenia nowych wartości, podczas gdy ludzkie zasoby w większej mierze to kategoria statyczna i ilościowa *(Białón Ł., 2002)*. Analizując pracowników pod względem skuteczności (analiza umiejętności) można dobierać odpowiednie szkolenie dla pracowników. Pozwoli to na zwiększenie jakościowej kategorii kapitału ludzkiego.

15. WNIOSKI Z BADAŃ

W niniejszej pracy autor skupiał się na opracowaniu metody uporządkowania przepływu danych w podmiocie gospodarczym. W opracowaniu zostały wykorzystane dane uzyskane w laboratorium medycznym w szpitalu klinicznym. Problematyka badań polegała na ujawnieniu istniejących zależności organizacyjno-technicznych funkcjonowania laboratorium pod wpływem czynników technologicznych oraz ludzkich i finansowych oraz znalezienie sposobu zwiększenia skuteczności jego działania. Na podstawie danych uzyskanych w laboratorium autor zobrazował procesy zachodzące w laboratorium medycznym w postaci diagramu przepływu danych. Rolę terminatora (zewnętrznej jednostki, która komunikuje się z systemem i pozostaje poza systemem) pełni klient, czyli oddział szpitalny lub pacjent. Pracownie diagnostyczne pełnią rolę magazynu danych. Diagram uwzględnia wszystkie procesy związane z przepływem próbki w laboratorium zaczynając od pobrania krwi u pacjenta i kończąc wynikami badań. Pozwoliło to na sprecyzowanie zasady działania badanego podmiotu gospodarczego i szczegółowych procesów.

Celem szczegółowym badań było wyznaczenie wąskich gardeł w trakcie przepływu próbek przez laboratorium. Przy pomocy teorii kolejek autorowi udało się dokonać analizy wiarygodności powstawania kolejek w laboratorium i sprecyzować miejsca, które mogą spowodować powstawanie kolejek. Powstające kolejki sygnalizują o nierównomiernym obciążeniu analizatorów i pracowników. Analiza potwierdziła założenie, że podmiot gospodarczy posiadał problematyczne obszary które wymagały uporządkowania przepływu danych. Aby uzyskać stabilizację obciążenia analizatorów oraz rytmiczność pracy diagnostów laboratoryjnych jak również zwiększyć efektywność wykorzystania analizatorów, zmniejszyć zużycie odczynników reakcyjnych i ilość błędnych badań autor opracował algorytm harmonogramowania procesów zachodzących w organizacji wspomagany systemami informatycznymi. Przy pomocy algorytmu udało się standaryzować otrzymane dane. Pojedyncze pliki udało się połączyć w jeden plik, który miał większą informacyjną wagę tym samym tworząc big

data. Przy pomocy sieci neuronowej autor przeanalizował big datę pod względem zależności pomiędzy zleceniodawcami a rodzajem i ilością zlecanych badań. Przy pomocy sieci neuronowej udało się powiązać obciążenia z dniem tygodnia, zauważyć wpływ poru roku na obciążenia laboratorium. Dni tygodnia podzielono na 6 trybów pracy. Przy pomocy sieci neuronowej autorowi udało się również wyznaczyć 7 komponentów które posiadają wspólne korelację. Komponenty pomogły zdefiniować reguły na podstawie których sieć neuronowa prognozuje obciążenie w zależności od rodzaju badań Na podstawie wyżej wymienionych komponentów autor nadał ograniczenia sieci neuronowej. Przy pomocy tych działań udało się uzyskać prognozę obciążenia laboratorium w kolejnym dniu. Posiadając taką wiedzę można uzyskać stabilizację obciążenia analizatorów oraz rytmiczność pracy diagnostów laboratoryjnych jak również zwiększyć efektywność wykorzystania analizatorów, zmniejszyć zużycie odczynników reakcyjnych i ilość błędnych badań.

Aby pokazać uniwersalność algorytmu harmonogramowania procesów, które zostały przetestowanie na danych uzyskanych w laboratorium, autor zastosował algorytm w przedsiębiorstwach produkcyjnych zajmujących się obróbką blach. Ze względu na różnicę badanych podmiotów gospodarczych dotyczących planowania obciążeń autor zdecydował się przetestować algorytm pod innym kątem. Analizowane przedsiębiorstwa mają stałych klientów oraz podpisane umowy na parę lat do przodu, posiadają również działy planowania i sterowania produkcją które równomiernie obciążają maszyny i ludzi. W tym przypadku nie ma większego sensu szukać różnorodność w dniach tygodnia pod względem obciążeń. Dla tego w kolejnych krokach analizy autor skupił się na rytmiczności pracy. Autorowi udało się zobrazować jak duży wpływ ma czynnik ludzi, jakie są szanse awarii maszyny lub brak wykonania normy w przypadku połączenia operatora x i maszyny y. Ze względu na dużą liczbę maszyn i trzyzmianowy tryb pracy oraz różne doświadczenie, kompetencje i szkolenia operatorów istnieje duża liczba kombinacji połączeń operatorów i maszyn. Przy pomocy sieci neuronowej na podstawie danych uzyskanych z przedsiębiorstwa autorowi udało się pokazać graficznie różnice pomiędzy pracownikami, wytypować

najlepszego pracownika oraz maszyny, które wykonują najtrudniejsze detale. Tego rodzaju działaniami autor pokazał inną odsłonę możliwości sieci neuronowej i opracowanego algorytmu harmonogramowania w porównaniu do analizy poprzedniego podmiotu gospodarczego. Opracowany przez autora algorytm posiada możliwość komponowania zmian z najlepszymi operatorami lub ustawienia operatorów maszyn na określone stanowiska zwiększając efektywność pracy lub zmniejszając ryzyko powstania awarii lub braków. Chociaż autorowi nie udało się przetestować algorytmu harmonogramowania na podobnych podmiotach gospodarczych, jednak różnice badanych podmiotów pomogły pokazać uniwersalność opracowanego algorytmu, który posiada w sobie możliwości do rozbudowania pod względem innych analiz.

16. KIERUNKI DALSZYCH BADAŃ

W niniejszej rozprawie autor podjął próbę stworzenia uniwersalnego algorytmu harmonogramowania procesów zachodzących w organizacji wspomagany systemami informatycznymi, który pozwoliłby na umożliwienie tworzenia prognoz obciążeń na kolejne dni, ułatwił doskonalenie systemu zarządzania warunkami pracy itd. Po analizie danych uzyskanych w laboratorium oraz w przedsiębiorstwie produkcyjnym zauważalna jest różnica zastosowań algorytmu. Wnioski wskazują, że dla uzyskania uniwersalnego algorytmu konieczne jest przeprowadzenie kolejnych prób (np. przeanalizowanie większej ilości danych i uzyskanie bardziej przybliżonych prognoz) i szczegółowych analiz, aby dostosować obecny algorytm do przedsiębiorstw, które mają stałą ilość zleceń, które mogą zaplanować w czasie oraz przedsiębiorstw, które nie posiadają długoterminowych zamówień.

W przypadku małych firm produkcyjnych obowiązki planisty wykonuje z reguły kierownik, który najlepiej zna i czuje swoją produkcję. Niestety wraz z rozwojem firmy i większą ilością realizacji, takie planowania staje się nie tylko mało efektywne, ale również coraz mniej skuteczne.

Rozbudowa algorytmu pod względem długoterminowego planowania znalazłaby zastosowania w małych przedsiębiorstwach z niestabilnym obciążeniem zamówieniami.

W przypadku średnich i większych firm zatrudnia się planistę lub nawet tworzy cały dział planowania. W tych przypadkach często można spotkać narzędzia wspomagające proces planowania: rozbudowane arkusze Excel, system ERP, system MRP lub ASP. Niestety w tym przypadku często brakuje zrozumienia zasad planowania, przez co w 100% polegamy na narzędziach, a często bywa tak, że brak jednego małego elementu "niszczy" cały plan. Opracowany przez autora algorytm mógłby być wykorzystywany jako narzędzie wspomagające W tym przypadku dalszymi kierunkiem rozbudowy algorytmu mogłoby służyć rozwinięcie funkcjonalności optymalizacyjnych związanym z efektywnością zasobów ludzkich, prognozowania awaryjności maszyn, skutecznością zarządzania parkiem maszynowym itd.

LITERATURA

1. *Białko M., Sztuczna inteligencja i elementy hybrydowych systemów ekspertowych, Politechnika Gdańska, Gdańsk 2005.*
2. *Białoń L., Metodologiczne problemy określenia kapitału ludzkiego, Wydawnictwo Politechniki Warszawskiej, Warszawa, 2002.*
3. *Bielecki S., Parol M., Zastosowanie sztucznych sieci neuronowych do szacowania spadków napięcia w sieciach niskich napięć, Przegląd Elektrotechniczny, Warszawa 2007*
4. *Briggs K., Implementing exact real arithmetic in Python, C++ and C, Theoretical Computer Science, 2006.*
5. *Czachórski T., Analityczne modele kolejkowe w ocenie efektywności pracy systemów i sieci komputerowych, Polska Akademia Nauk, Gliwice, 2003.*
6. *Chang C., Kayed M., Girgis M.R., Shaalan K.F., A survey of web information extraction systems. „IEEE Transactions on Knowledge and Data Engineering", IEEE, 2006.*
7. *Cisco, Cisco Visual Networking Index: Global Mobile Data Traffic Forecast Update, 2011-2016, 2012.*
8. *Cox M., Ellsworth D., Managing Big Data for Scientific Visualization, ACM SIGGRAPH '97 Course #4, Exploring Gigabyte Datasets in Real-Time: Algorithms, Data Management, and Time-Critical Design, Los Angeles 1997.*
9. *de Lathauwer L., De Moor B., Vandewalle J.: On the Best Rank-1 and Rank-(R1 , R2 , . . . , RN) Approximation of Higher-Order Tensors. SIAM J. Matrix Anal. Appl. 21(4), 2000.*
10. *Doug L., Data Management: Controlling Data Volume, Velocity, and Variety, „Application Delivery Strategies", META Group (currently with Gartner) 2001.*
11. *Draminski M., Dabrowski M., Diamanti K., Koronacki J., Komorowski J.: Discovering Networks of Interdependent Features in High-Dimensional Problems. In: Japkowicz N., Stefanowski J. (eds) Big Data Analysis: New Algorithms for a New Society 2016.*
12. *Fan W., Bifet A., Mining big data: current status, and forecast to the future, „ACM SIGKDD Explorations Newsletter", SIGKDD Explorations, ACM, New York, USA, 2012.*
13. *Fehily C., Po prostu Python, Helion, 2002.*
14. *Filipowicz, B., Kwiecień, J., Zastosowanie teorii kolejek do modelowania struktur administracyjnych w szkolnictwie, Wydawnictwa AGH, Kraków, 2008.*
15. *Gągolewski M., Bartoszuk M., CenaA., Przetwarzanie i analiza danych w języku Python, PWN, Warszawa, 2016.*
16. *Gershenfeld N., Chuang I., „Molekularne komputery kwantowe"; Świat Nauki, 1998*
17. *Gromada M., Redukcja wymiaru próby metodą analizy składowych głównych, uniwersytet warszawski, 2009.*

18. *Harman H, Modern Factor Analysis. 3rd Edition, The University of Chicago Press, Chicago 1976.*
19. *Haykin S., Neural Networks A Comprehensive Foundation, New Jersey 1999.*
20. *Hetland M. L., Python Algorithms, Apress, 2014.*
21. *Jacyna M.: The structure and characteristics of the elements of a multimodal transport corridor in respect to traffic distribution modeling, Archives of Transport, vol. 9, iss. 1–2, Warsaw 1997.*
22. *Jacyna M.: Modelowanie i ocena systemów transportowych, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2009.*
23. *Jacyna M.: Wybrane zagadnienia modelowania systemów transportowych, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2009.*
24. *Jacyna M., Żak J., Zastosowanie teorii kolejek do analizy i oceny procesu transportowego w centrum logistycznym, Wydział Transportu Politechniki Warszawskiej, Logistyka, Warszawa, 2012.*
25. *Kachniewska M., Big Data Analysis jako zrodlo przewagi konkurencyjnej przedsiębiorstw i regionów turystycznych, SGH, Warszawa 2014.*
26. *Katal A., Wazid M., Goudar R.H., Big Data: Issues, Challenges, Tools and Good Practices, Sixth International Conference on Contemporary Computing (IC3), IEEE, Noida 2013.*
27. *Kiczkowiak T., Ociepa Z., Grymek S., Problemy analogowej realizacji sztucznej sieci neuronowej, Zeszyty Naukowe Wydziału Mechanicznego Politechnika Koszalińska, Koszalin 2002.*
28. *Kłyszejko-Stefanowicz L, 2003. Ćwiczenia z biochemii. Wydawnictwo Naukowe PWN, 2003.*
29. *Knowlton James O.,Python. Projekty do wykorzystania, Wydawnictwo Helion 2010.*
30. *Kolda, T. G., Bader, B. W.: Tensor decompositions and applications, SIAM Review 51(3), 2009.*
31. *Kopańska-Bródka D., Wybrane metody badań operacyjnych w zarządzaniu: problemy i zadania, Wydawnictwo Akademii Ekonomicznej im. Karola Akademickiego, Katowice 2006.*
32. *Kopocińska I., O pewnym modelu z teorii kolejek z uwzględnieniem zniecierpliwienia klientów, Zastosowania matematyki, Wrocław 1963.*
33. *Korbicz J., Obuchowicz A., Uciński D., "Sztuczne sieci neuronowe. Podstawy i zastosowania, Warszawa 1994.*
34. *Kos A., Wykład "Przemysłowe zastosowania sztucznej inteligencji", 2003/2004*
35. *Krauze S., Nowe spojrzenie na big data, Harvard Business Review, Nr 135, 2014.*
36. *Krystek J., Zaborowski M., Kosztowe i czasowe kryteria optymalności algorytmu nadążnego harmonogramowania produkcji, Zeszyty naukowe politechniki śląskiej, 2006.*
37. *Kukuła K., Badania operacyjne w przykładach i zadaniach, Wydawnictwo Naukowe PWN, Warszawa 1998.*

38. *Liaushuk A., Model optymalizacji procesówzachodzących w trakcie badań medycznych w laboratorium klinicznym, CreativTime, Kraków 2017.*
39. *Liaushuk A.,Jasiak A., Metoda uporządkowania przepływu danych w podmiocie gospodarczym na podstawie diagramu przepływu danych i teorii kolejek, Zeszyty naukowe Politechniki Poznańskiej, Poznań 2019.*
40. *Liaushuk A.,Jasiak A., Method of organizing of the data flow in business entity on the basis of data flow diagram and the theory of queues, Research in Logistics & Production, Poznań 2019.*
41. *Lutz M., Python. Wprowadzenie. Wydanie IV, Helion, 2010.*
42. *Łukaszewicz J., Teoria kolejek czyli obsługi masowej, Zastosowania matematyczne, Wrocław 1965*
43. *Marzec J., Osiewalski J., Bivariate ZIP-CP type model in the joint analysis of count variables, Folia Oeconomica Cracoviensia , Kraków, 2012.*
44. *Matwin S., Uczenie się maszynowe: cztery lekcje - i co dalej?, Biuletyn PSSI 2013.*
45. *Mazur M.: Pojęcie systemu i rygor ich stosowania, Postępy Cybernetyki, z. 2, 1987.*
46. *Mayer-Schönberger, Cukier K., Big Data, Rewolucja, która zmieni myślenie, pracę i życie, MT Biznes, Warszawa 2014.*
47. *McKinsey Global Institute, Big data: The next frontier for innovation, competition, and productivity 2011.*
48. *Michlowicz E.: Podstawy logistyki przemysłowej, AGH, Kraków, 2002.*
49. *Morajda J., Modelowanie sieci neuronowych, Zeszyty Naukowe / Akademia Ekonomiczna w Krakowie, Kraków 1996.*
50. *Morajda J., Wybrane możliwości zastosowań sieci neuronowych w ekonomii i zarządzaniu, Zeszyty Naukowe / Akademia Ekonomiczna w Krakowie, Kraków 1997.*
51. *Niepostyn S., Diagramy obiegu dokumentów w modelowaniu procesów biznesowych, Instytut Informatyki PW, 2007.*
52. *Niepostyn S., Bluemke I., Diagramy obiegu dokumentów a uml w modelowaniu procesów biznesowych, Politechnika Warszawska, Warszawa, 2008.*
53. *Odlanicka-Poczobutt M., Kulińska E., Zastosowanie diagramu przepływu danych w analizie systemowej procesu realizacji zamówienia klienta interco, PTZP, Opole, 2015.*
54. *Olczyk D., Modelowanie strukturalne : definicje notacja techniki i narzędzia, Zeszyty Naukowe Warszawskiej Wyższej Szkoły Informatyki, Warszawa, 2010.*
55. *Ordysiński T., DFD – Diagram przepływu danych (Data Flow Diagram) http://www.tomaszordysinski.pl 2017*
56. *Ossowski R., Sieci neuronowe w modelowaniu konstytutywnym,Politechnika Gdańska, Gdańsk 2007.*
57. *Pietrasieński J., Siergiejuk P., Python w zastosowaniach naukowych, Mechanik, 2012.*
58. *Rossum G., Python tuto rial, Technicał Report, Amsterdam, 1995.*

59. *Sanocki Ł., Gołda A.„ Wstęp do sieci neuronowych, Katedra Elektroniki AGH, 2005.*
60. *Słowik A., Białko M., Zastosowanie algorytmu ewolucyjnego do trenowania jednokierunkowych płaskich sztucznych sieci neuronowych, Wrocławskie Towarzystwo Naukowe, Wrocław 2007.*
61. *Smogór-Szęszoł E., Ściana A., Modelowanie sieci transportowej w celu optymalizacji jej funkcjonowania. Logistyka – nauka 2014.*
62. *Summerfield M., Programming In Python 3, Addison-Wesley, Indiana, 2011.*
63. *Szwabe A., Misiorek P., Ciesielczyk M., Tensorowe przetwarzanie Big Data, Politechnika poznańska, Poznań 2016.*
64. *Tabakow M., Korczak J., Franczyk B., BIG DATA – Definicje, wyzwania i technologie informatyczne, Informatyka ekonomiczna business informatics 1(31), Wrocław 2014*
65. *Tadeusiewcz R., Sieci neuronowe, Kraków 1992*
66. *Tarapata Z., Algorytmy harmonogramowania zsynchronizowanego przemieszczania wielu obiektów, Badania Operacyjne i Decyzje, 2008.*
67. *Trocki M., Outsourcing., Polskie Wydawnictwo Ekonomiczne, Warszawa 2001.*
68. *van Rossum G., Drake F.L., (ed.), The Python Language Reference Manual (version 2.5), Network Theory Ltd, 2006.*
69. *Walukiewicz S.: Programowanie dyskretne, PWN, Warszawa 1986.*
70. *Wieczorkowski J., Wykorzystanie koncepcji big data w administracji publicznej, Roczniki Kolegium Analiz Ekonomicznych / Szkoła Główna Handlowa, Warszawa 2014.*
71. *Wieczorkowski J., Big Data - aspekt technologiczny i ekonomiczny vs. aspekt społeczny, Zeszyty Naukowe Uniwersytetu Szczecińskiego, Szczecin 2014*
72. *Wielki J., Analiza możliwości wykorzystania zjawiska big data w e-biznesie, Prace Naukowe Uniwersytetu Ekonomicznego w Katowicach, Katowice 2014.*
73. *Woch J. , Kształtowanie płynności ruchu w gęstych sieciach transportowych, Polska Akademia Nauk – Oddział w Katowicach, Katowice, 1998.*
74. *Woch J., Statystyka procesów transportowych. Wydawnictwo Politechniki Śląskiej, Gliwice, 2001.*
75. *Woch J., Complex railway junctions capacities and railway network effectiveness. Archives of Transport, 2001.*
76. *Ziółkowski J., Zajda U., Zastosowanie teorii kolejek w logistyce, Społeczna Akademia Nauk, Warszawa, 2016.*
77. *Zygała R., Możliwości rozwijania systemów analitycznych dla MŚP w oparciu o środowisko języka Python, Informatyka Ekonomiczna, Wrocław, 2016.*
78. *https://www.alexejgossmann.com/tensor_decomposition_CP/ [dostęp 08.2019]*
79. *https://www.boundless.com/biology/the-circulatory-system/components-of-the-blood/plasma-and-serum/ [dostęp 08.2019]*
80. *http://www.cmkarpacz.pl/strona-glowna/morfologia-krwi/ [dostęp 08.2019]*
81. *http://jurasza.umk.pl/misja-szpitala/ [dostęp 05.2019]*

82. *https://www.klinikiserca.pl/oferta/pracownia-zaburzen-ukladu-krzepniecia-krwi/o-pracowni/ [dostęp 08.2019]*
83. *https://www.medipment.pl/produkt/DIAGON-D-Cell-5D-39286/ [dostęp 08.2019]*
84. *https://www.medipment.pl/produkt/Roche-Cobas-INTEGRA-400-Plus-41053/ [dostęp 08.2019]*
85. *https://www.medme.pl/artykuly/biochemia-krwi-badanie-biochemiczne-interpretacja-wynikow-i-normy,67467.html [dostęp 08.2019]*
86. *https://mfiles.pl/pl/index.php/Diagramy_przep%C5%82ywu_danych [dostęp 04.2019]*
87. *https://mfiles.pl/pl/index.php/Teoria_kolejek [dostęp 04.2019]*
88. *http://www.myvmc.com/anatomy/blood-function-and-composition/ [dostęp 08.2019]*
89. *https://www.python.org/about/ [dostęp 04.2017]*
90. *http://standaryzacjadanych.hoga.pl/czyszczenie.asp [dostęp 04.2017]*

SPIS RYSUNKÓW

Rysunek 1: Schemat procesu modelowania.....22
Rysunek 2: Ogólna procedura konstruowania modelu.....25
Rysunek 3: Wizualizacja laboratorium medycznego..... 27
Rysunek 4: Schemat przedstawiający działalność laboratorium w postaci ogólnego procesu..... 28
Rysunek 5: Frakcje krwi po wirowaniu..... 32
Rysunek 6: Schemat sztucznej sieci neuronowej zwanej perceptronem..... 46
Rysunek 7: Model neuronu..... 47
Rysunek 8: Struktura ogólna sieci rekurencyjnej.....48
Rysunek 9: Sieć typu mapa Kohonena.....49
Rysunek 10: Ogólny schemat DPD laboratorium medycznego.....50
Rysunek 11: Schemat przepływu trzech rodzajów próbek z krwią w laboratorium medycznym.....51
Rysunek 12: Schemat przepływu trzech rodzajów próbek z krwią w laboratorium medycznym.....53
Rysunek 13: Fragment raportu z kliniki endokrynologii.....59
Rysunek 14: Schemat czyszczenia danych.....60
Rysunek 15: Fragment kodu stworzonego w Python, który został wykorzystany do łączenia plików i czyszczenia danych.....64
Rysunek 16: Histogram ilości badań zleconych przez wszystkie kliniki w ciągu jednego miesiąca.....65
Rysunek 17: Histogram przedstawia ilość zleceń z kliniki kardiologii i całkowitą ilość zleceń ze szpitalu.....66
Rysunek 18: Zrzut ekranu przedstawia rodzaje i ilości zleconych badań przez poszczególne kliniki w programie Google OpenRefine.....67
Rysunek 19: Rysunek przedstawia rozkład CP dla 3-kierunkowego tensora X.....68
Rysunek 20: Skala ilościowa dla rozkład CP.....69
Rysunek 21: Rozkład CP dla 22 dnia kalendarzowego.....70
Rysunek 22: Rozkład CP dla 23 dnia kalendarzowego.....70
Rysunek 23: Rozkład CP dla 24 dnia kalendarzowego.....71
Rysunek 24: Rozkład CP dla 25 dnia kalendarzowego.....71
Rysunek 25: Rozkład CP dla 7 dnia kalendarzowego dla wybranych badań.....72
Rysunek 26: Rozkład CP dla 8 dnia kalendarzowego dla wybranych badań.....72
Rysunek 27: Rozkład CP dla 9 dnia kalendarzowego dla wybranych badań.....73
Rysunek 28: Wykres piargowy powiązań danych.....74
Rysunek 29: Powiększony wykres piargowy powiązań danych.....74
Rysunek 30: Wykres ilości zlecanych badań przed rozpoczęciem i w trakcie okresu letniego.....75
Rysunek 31: Obraz wielowymiarowej piramidy wykonany analizą czynnikową.....77
Rysunek 32: Wykres porównujący dni w zależności od tygodnia.....78
Rysunek 33: Macierz przedstawiająca podział dni tygodnia na 6 trybów pracy.....79

Rysunek 34: Macierz Hankela dla danych uzyskanych z jednego tygodnia.....80
Rysunek 35: Obraz wielowymiarowej piramidy wykonany analizą czynnikową dla głównych komponentów uzyskanych na podstawie matrycy.....81
Rysunek 36: Wykres korelacji komponentów PC5 i CP4.....82
Rysunek 37: Wykres korelacji komponentów PC2 i CP1.....82
Rysunek 38: Wykres korelacji komponentów PC2 i CP3.....83
Rysunek 39: Jedna z reguł na której jest oparte prognozowanie sieci neuronowej.....84
Rysunek 40: Prognoza wiarygodności obciążenia laboratorium na kolejne dwa dni....86
Rysunek 41: Obraz wielowymiarowej piramidy wykonany analizą czynnikową dla głównych komponentów uzyskanych na podstawie matrycy dla przedsiębiorstwa produkcyjnego.....90
Rysunek 42: Podział maszyn na 3 grupy.....91
Rysunek 43: Porównanie zakładanego czasu pracy i rzeczywistego.....93
Rysunek 44: Porównanie zakładanego czasu pracy i rzeczywistego rozłożonych funkcją PCA angle.....94
Rysunek 45: Porównanie wyników pracy jednego operatora w stosunku do reszty osób.....95
Rysunek 46: Porównanie wyników pracy jednego operatora w stosunku do reszty osób rozłożonych funkcją PCA angle.....96
Rysunek 47: Podział operatorów na 3 grupy.....97
Rysunek 48: Wykres przedstawia maszyny które są najczęściej używane do skomplikowanych zleceń.....98
Rysunek 49: Wykres przedstawia najlepszego pracownika pod względem efektywności w porównaniu do reszty zmiany.....99
Rysunek 50: Schemat przedstawia algorytm harmonogramowania procesów zachodzących w organizacji wspomagany systemami informatycznymi.....101

SPIS WZORÓW

(1) reprezentacja zbioru krotek w przestrzeni tensorowej.....43
(2) intensywność przepływu probówek.....54
(3) średni czas rejestracji próbek.....55
(4) intensywność przepływu.....55
(5) stabilność systemu.....55
(6) intensywność przepływu probówek.....56
(7) średni czas rejestracji próbek.....56
(8) intensywność przepływu.....56
(9) stabilność systemu.....56
(10) stosunek współczynnik przeciążenia do ilości kanałów obsługi.....56
(11) wiarygodność oczekiwania w kolejce.....57
(12) rozkład CP dla 3-kierunkowego tensora X.....68
(13) iloczyn zewnętrzny tensorów.....68

SPIS ZRÓDEŁ RYSUNKÓW

1) https://www.czasopismologistyka.pl/artykuly-naukowe/send/308-artykuly-na-plycie-cd-6/5171-artykul [dostęp 20.12.2019]

2) https://www.boundless.com/biology/the-circulatory-system/components-of-the-blood/plasma-and-serum/ [dostęp 20.12.2019]

3) http://galaxy.uci.agh.edu.pl/~vlsi/AI/wstep/ [dostęp 20.12.2019]

4) http://standaryzacjadanych.hoga.pl/czyszczenie.asp [dostęp 20.12.2019]

5) https://www.alexejgossmann.com/tensor_decomposition_CP/ [dostęp 08.2019]