

Streszczenie

Optimalizacja dawkowania leków w chorobie Parkinsona na podstawie sygnałów z pomiarów sensorowych

Tomasz GUTOWSKI

Słowa kluczowe: uczenie maszynowe, choroba Parkinsona, optymalizacja, sztuczna inteligencja, przetwarzanie sygnałów

Choroba Parkinsona (PD) stwarza wiele trudności w terapii wymagając dokładności oraz głębokiego zrozumienia indywidualnych potrzeb pacjentów z chorobą. W tej pracy zbadano zastosowanie metod uczenia maszynowego i metod optymalizacji w celu wsparcia terapii PD skupiając się na budowaniu zindywidualizowanych harmonogramów przyjmowania leków. Głównym celem pracy jest przygotowanie metody, które będzie w stanie sugerować optymalne dawki leków oraz czasy ich przyjęcia, w szczególności dla lewodopy - głównego leku stosowanego w terapii PD, tak aby utrzymać pacjenta w optymalnym stanie jak najdłużej w ciągu dnia.

Zagadnienia zawarte w pracy podzielono na cztery główne obszary:

- ocena intensywności objawów,
- modelowanie reakcji na lek,
- optymalizacja harmonogramów przyjmowania leków,
- implementacja systemu do monitorowania pacjentów.

W ramach oceny intensywności objawów zbudowano modele uczenia maszynowego oraz głębokiego, których celem jest dokonanie oceny aktualnego stanu pacjenta w oparciu o dane zebrane z sensorów wbudowanych w urządzenia mobilne oraz opaski. Obiektem badań niniejszej pracy było określenie, jak zróżnicowane ćwiczenia mogłyby zostać wykorzystane do predykcji intensywności poszczególnych objawów i ogólnego stanu pacjenta. Najlepsze wyniki uzyskano korzystając z sygnałów z sensorów inercyjnych takich jak akcelerometry i żyroskopy. Ponadto badania wykazały również efektywność klasycznych metod uczenia maszynowego oraz metod głębokich. Metody uczenia głębokiego radziły sobie lepiej wymagając jednocześnie więcej danych.

Modelowanie odpowiedzi na lek obejmowało budowanie modeli predykcyjnych w celu zrozumienia indywidualnych reakcji pacjentów na leki. Modele te zostały oparte na sieciach neuronowych, w szczególności wykorzystano komórki LSTM, które wykazały wysoką dokładność w predykcji stanów pacjenta po przyjęciu dawek leków. Podczas badań modele te zostały zweryfikowane na danych pacjentów syntetycznych oraz rzeczywistych, pokazując, że integracja danych demograficznych i klinicznych wspiera personalizację predykcji reakcji na lek.

Optymalizacja harmonogramów dawkowania leków wykorzystwała algorytmy optymalizacji i uczenie ze wzmocnieniem w celu zbudowania zindywidualizowanych harmonogramów przyjmowania leków. Metody te zapewniły elastyczność w rozmiarach dawek i okresach między nimi, pozwalając na personalizację planów leczenia. Porównanie wyników optymalizacji uzyskanych z wykorzystaniem modeli farmakokinetyczno-farmakodynamicznych i modeli uczenia maszynowego pokazało, że różnice są niewielkie, potwierdzając zastosowalność zaproponowanych metod.

W ostatniej części rozprawy zaprezentowano system zaimplementowany w celu wsparcia zbierania danych i monitorowania stanu pacjentów. System składa się z aplikacji mobilnej dla pacjenta oraz aplikacji internetowej dla klinicystów. Aplikacja mobilna pozwala pacjentom na rejestrowanie objawów, przyjętych dawek leków oraz innych istotnych informacji w czasie rzeczywistym. Dane te następnie są synchronizowane z aplikacją internetową, gdzie klinicyści mogą monitorować postęp pacjentów oraz podejmować decyzje co do terapii. Integracja tych dwóch narzędzi ułatwia zbieranie danych w czasie rzeczywistym oraz ciągłe monitorowanie stanu pacjentów, co pozwala na szybkie reagowanie na zmiany w stanie pacjenta. Dzięki przyjaznemu interfejsowi użytkownika dla pacjentów i klinicystów, system ten wspiera ciągłą opiekę nad pacjentem i umożliwia rozwój zaawansowanych, zindywidualizowanych strategii leczenia, które dostosowane są do indywidualnych potrzeb pacjentów.

Wyniki badań przedstawione w pracy pokazują możliwości istotnej poprawy w zarządzaniu objawami oraz jakości życia pacjentów poprzez większą indywidualizację leczenia. Przyszłe badania powinny uwzględnić większą liczbę pacjentów oraz badań, zbadać wpływ innych czynników na stan pacjenta oraz aktualizację zadań optymalizacyjnych, aby zwiększyć dokładność oraz zastosowalność metody.

Podsumowując, praca ta prezentuje kompleksowe podejście do indywidualizacji leczenia PD, poprzez wykorzystanie modelu uczenia maszynowego i optymalizacji, oferując obiecujący kierunek rozwoju przyszłych terapii w PD.