

Computational intelligence methods for uncertain medical and sensor data

Ph.D. Dissertation

mgr inż. Olga Kamińska

Supervisor: dr hab. Katarzyna Kaczmarek-Majer

POLISH ACADEMY OF SCIENCES

Systems Research Institute

Warsaw, Poland

2025

Metody inteligencji obliczeniowej dla niepewnych danych medycznych oraz danych pochodzących z urządzeń sensorycznych

Rozprawa Doktorska

mgr inż. Olga Kamińska

Promotor: dr hab. Katarzyna Kaczmarek-Majer

Polska Akademia Nauk
Instytut Badań Systemowych
Warszawa, Polska
2025

Streszczenie w języku polskim

Wspomaganie lekarzy w opiece nad pacjentami dotkniętymi chorobami afektywnymi stanowi znaczące wyzwanie, gdyż tradycyjne metody modelowania danych stosowane w celu predykcji lub monitorowania stanu pacjenta nie uwzględniają wielu niepewności. Choroba afektywna dwubiegunowa to przewlekłe schorzenie psychiczne, charakteryzujące się ekstremalnymi wahaniami nastroju, obejmującymi epizody maniakalne i depresyjne. Ograniczenia istniejących systemów komputerowych skłoniły do poszukiwania bardziej solidnych technik monitorowania, przy czym metody inteligencji obliczeniowej okazały się obiecujące.

W tym kontekście niniejsza rozprawa doktorska podejmuje wyzwanie opracowania zaawansowane metody inteligencji obliczeniowej, wykorzystujące dane akustyczne do monitorowania zmian nastroju u pacjentów z chorobą afektywną dwubiegunową, ze szczególnym uwzględnieniem niepewności wynikającej z charakteru zebranych danych głosowych oraz danych pochodzących z ankiet psychiatrycznych.

Praca porusza zagadnienie selekcji istotnego zbioru cech akustycznych, które precyzyjnie charakteryzują określone stany afektywne, przy jednoczesnym zapewnieniu interpretowalności wyników oraz uwzględnieniu niepewności związanej z danymi i etykietami uzyskanymi od lekarzy. Aby sprostać tym wyzwaniom, rozprawa wprowadza metodę *“Uncertainty Aware Advanced Feature Selection”*, umożliwiającą selekcję cech istotnych dla oceny stanu pacjenta. Dzięki uwzględnieniu niepewności związanej z nadawaniem etykiet przez psychiatrów podczas etapu wyboru istotnych cech wzrasta dokładność klasyfikacji stanu pacjenta. Następnie zaproponowana metoda zatytułowana *“Explainable Compositional Multilayer Perceptron”* uwzględnia niepewność związaną z ekstrapolacją etykiety medycznej oraz wykorzystuje architekturę sieci neuronowej z dwoma warstwami wyjściowymi, odpowiadającymi za ocenę stanu pacjenta i jego symptomów. Integracja tej metody z technikami wyjaśnialnymi sprawia, że zaproponowane podejście jest nie tylko dokładne, ale także bardziej interpretowalne, co ma kluczowe znaczenie w zastosowaniach klinicznych.

Ponadto, w niniejszej rozprawie zaproponowano metodę podejmującą problem niekompletnego i niespójnego etykietowania poprzez ocenę podobieństwa między danymi oznakowanymi a nieoznakowanymi, co umożliwia bardziej efektywne wykorzystanie dużych i często niespójnych zbiorów danych. Opracowana metoda *“Semi-supervised Cluster Validation Agreement”* umożliwia weryfikację spójności skupień w sytuacji, gdy dostępne są dane częściowo oznakowane, biorąc pod uwagę odległość od danej etykiety. Ten krok ma kluczowe znaczenie, ponieważ wykazuje, że skupienia są istotne i mogą być interpretowane w szerszym kontekście badań.

Dissertation summary

Assisting psychiatrists in the care of patients affected by affective disorders poses a significant challenge, as traditional data modeling methods used to predict or monitor a patient’s condition do not account for numerous uncertainties. Bipolar disorder is a chronic psychiatric condition characterized by extreme mood swings, including manic and depressive episodes. The limitations of existing computer systems supporting this problem have led to the search for more robust monitoring approaches, with computational intelligence methods offering promising solutions.

In this context, the doctoral dissertation addresses the challenge of developing advanced computational intelligence methods using acoustic data to monitor mood changes in patients with bipolar disorder, with particular emphasis on incorporating the uncertainty resulting from the nature of the collected voice data and psychiatric survey data.

The proposed approach enables selecting a subset of acoustic features that accurately characterize specific affective states while ensuring the interpretability of the results and accounting for the uncertainty associated with the data and the medical labels. To meet these challenges, the dissertation introduces the “*Uncertainty Aware Advanced Feature Selection*” method, which is used for selecting features for assessing the patient’s condition. By taking into account the uncertainty associated with psychiatrists’ labeling during the feature selection stage, the accuracy of patient state classification is improved.

Next, the novel “*Explainable Compositional Multilayer Perceptron*” method presents a comprehensive approach to the problem, addressing the uncertainty related to the extrapolation of medical labels and employing a neural network architecture with two output layers—one for evaluating the patient’s condition and the other for assessing their symptoms. The integration of this method with explainable techniques makes the proposed approach not only comprehensively effective but also transparent, which is crucial in clinical applications.

Furthermore, this dissertation addresses the problem of incomplete and inconsistent labeling by evaluating the similarity between partially labeled datasets, enabling more efficient use of large and often inconsistent datasets. The proposed method “*Semi-supervised Cluster Validation Agreement*” verifies the consistency of clusters between labeled and unlabeled data by considering the distance from a given label. This step is crucial, as it demonstrates whether the clusters are relevant and can be interpreted in a broader research context.