

PhD Thesis summary

**Predicting binding affinity of small
molecules in ligand-receptor systems
using neural networks.**

Wykorzystanie sieci neuronowych do przewidywania
aktywności związków niskocząsteczkowych w układach
ligand-receptor.

Marta Stępniewska-Dziubińska

Supervisor:

Dr hab. Paweł Siedlecki

Department of Bioinformatics
Institute of Biochemistry and Biophysics
Polish Academy of Sciences
Warsaw, Poland

Warsaw, 2020



Thesis summary

This thesis is an interdisciplinary work, that combines computer-aided drug design (CADD) with machine learning (ML). The main focus of this work is usage of deep neural networks for assessing small molecule ability to bind to a molecular target of interest. This concept is illustrated with two manuscripts: “Development and evaluation of a deep learning model for protein–ligand binding affinity prediction” and “Improving detection of protein–ligand binding sites with 3D segmentation”. In both works we propose new ways of addressing fundamental problems in structure-based drug design with 3D convolutional neural networks based on architectures used in computer vision. Network built for the first project – Pafnucy – predicts pK_i values for protein–ligand complexes. The model from the second work – Kalasanty – detects binding sites at protein surfaces. The first manuscript also describes a featurization mechanism that was used in both models – algorithm for converting 3D molecular structures into a representation that can be used as an input for neural networks or other *in silico* methods.

To showcase advantages and flaws of deep learning methods for CADD, I compare it to two alternative approaches: classical, semi-manual CADD methods; and classical ML models combined with extensive feature engineering. As examples for these approaches I use two manuscripts I co-authored: “DeCAF – Discrimination, Comparison, Alignment Tool for 2D PHarmacophores” and “Development of a protein–ligand extended connectivity (PLEC) fingerprint and its application for binding affinity predictions”. The first manuscript is an example of classical CADD method for ligand-based design, while the second one describes featurization mechanism developed for structure-based binding affinity prediction and its usage with different classes of ML methods.

The manuscripts are accompanied with an introduction, in which I compare and contrast presented approaches. I also briefly introduce fundamental concepts related to machine learning, focusing mostly on deep artificial neural networks, and computer-aided drug design and how these two fields can be combined.

Streszczenie rozprawy

Niniejsza rozprawa stanowi interdyscyplinarną pracę łączącą komputerowe projektowanie leków (CADD, ang. *computer-aided drug design*) z uczeniem maszynowym (ML, ang. *machine learning*). Jej głównym tematem jest wykorzystanie głębokich sieci neuronowych w projektowaniu związków niskocząsteczkowych zdolnych do oddziaływania z wysokim powinowactwem z wybranym celem molekularnym. Koncept ten ilustruję za pomocą dwóch publikacji naukowych: "Development and evaluation of a deep learning model for protein-ligand binding affinity prediction" oraz "Improving detection of protein-ligand binding sites with 3D segmentation". W obu pracach zaprezentowaliśmy nowe sposoby zaadresowania fundamentalnych problemów w projektowaniu leków opartych o strukturę (ang. *structure-based drug design*), wykorzystując trójwymiarowe konwolucyjne sieci neuronowe oparte o architektury wykorzystywane w wizji komputerowej. Sieć stworzona na potrzeby pierwszego projektu – Pafnucy – służy do przewidywania wartości pK_i dla kompleksów białko-ligand. Model przedstawiony w drugiej pracy – Kalasanty – wykrywa miejsca wiążące na powierzchni białek. Pierwsza z prac opisuje również reprezentację danych wykorzystywaną przez oba modele – trójwymiarową siatkę, opisującą gruboziarnisty rozkład cech atomowych w przestrzeni 3D.

Głębokie sieci neuronowe kontrastują z powszechnie stosowanymi alternatywami: klasycznymi modelami wykorzystywanymi w CADD oraz podejściem opartym o uczenie maszynowe i inżynierię cech. Jako przykłady wykorzystuję publikacje naukowe: "DeCAF – Discrimination, Comparison, Alignment Tool for 2D PHarmacophores" oraz "Development of a protein-ligand extended connectivity (PLEC) fingerprint and its application for binding affinity predictions". Pierwszy z manuskryptów stanowi przykład klasycznej metody stosowanej w projektowaniu w oparciu o ligandy (ang. *ligand-based design*), natomiast drugi opisuje reprezentację danych stworzoną na potrzeby opisu oddziaływania białko-ligand oraz przykłady jego wykorzystania do przewidywania powinowactwa z pomocą modeli uczenia maszynowego.

Publikacje opatrzone są wstępem, w którym porównuję prezentowane podejścia oraz umieszczam je w szerszym kontekście. Opisuję również podstawowe pojęcia związane z uczeniem maszynowym, ze szczególnym uwzględnieniem głębokich sieci neuronowych, oraz komputerowym projektowaniem leków oraz to, jak te dwie dziedziny przeplatają się ze sobą.