

ABSTRAK

KLASIFIKASI GEN ESENSIAL PADA *DROSOPHILA MELANOGASTER* BERDASARKAN PROTEIN *SEQUENCE* MENGGUNAKAN METODE *LONG SHORT-TERM MEMORY (LSTM)*

Oleh
Dina Putri Aulia

Gen esensial adalah gen yang sangat diperlukan untuk mendukung kehidupan organisme seluler. Penghapusan gen esensial pada organisme akan mengakibatkan kematian dan infertilitas. Mengklasifikasikan gen esensial ada 2 cara, yaitu dengan teknik eksperimental dan komputasi, namun teknik eksperimental membutuhkan sumber daya yang besar. Pada penelitian ini mengusulkan metode *Long Short-Term Memory (LSTM)* untuk mengklasifikasikan gen esensial pada *Drosophila melanogaster* berdasarkan protein *sequence*. *Drosophila melanogaster* adalah salah satu organisme yang sering digunakan untuk analisis *science*. Tujuan penelitian ini, yaitu mengukur dan mengklasifikasi hasil penelitian menggunakan algoritma *Long Short-Term Memory (LSTM)* dan membandingkan hasilnya dengan penelitian terdahulu oleh Beder, et al, (2021). Data dibagi dengan 2 skenario, yaitu : 80% *training* 20% *validation* ; dan 90% *training* 10% data *validation*. Pada dataset CEG memiliki distribusi kelas yang tidak seimbang sehingga dilakukan proses *Random Undersampling (RUS)* untuk menyeimbangkan kelas. Evaluasi model dilakukan dengan metrik evaluasi, yaitu PR-AUC, ROC-AUC, *sensitivity* dan *specificity*. Hasil kinerja yang paling baik pada dataset OEG didapatkan pada skenario pembagian data 80% *training* dan 20% *validation*, dengan nilai *sensitivity* 81%, *specificity* 76%, ROC-AUC 79% , PR-AUC 82%. Hasil yang paling baik pada dataset CEG diperoleh dari pembagian data 80% *training* dan data 20% *validation* dengan nilai yang didapat untuk *sensitivity* 73%, *specitifity* 50% ROC-AUC 61%, dan PR-AUC 45%.

Kata Kunci : Gen Esensial, Klasifikasi, *Drosophila melanogaster*, Protein *sequence*, LSTM.

ABSTRACT

CLASSIFICATION OF ESSENTIAL GENES IN DROSOPHILA MELANOGASTER BASED ON PROTEIN SEQUENCE USING LONG SHORT-TERM MEMORY UNIT (LSTM)

Oleh
Dina Putri Aulia

Essential genes are genes that are very necessary to support the life of cellular organisms. Deletion of essential genes in an organism will result in death and infertility. There are 2 ways to classify essential genes, specifically experimental and computational techniques, but experimental techniques require large resources. In this study, we propose the Long Short-Term Memory (LSTM) method to classify essential genes in *Drosophila melanogaster* based on protein sequences. *Drosophila melanogaster* is an organism that is often used for scientific analysis. The purpose of this research is to measure and classify research results using the Long Short-Term Memory (LSTM) algorithm and compare the results with previous research by Beder, et al, (2021). The data is divided into 2 scenarios, specifically 80% training 20% validation and 90% training 10% data validation. The CEG dataset has an unbalanced class distribution so a Random Undersampling (RUS) process is carried out to balance the classes. Model evaluation was carried out using evaluation metrics, specifically PR-AUC, ROC-AUC, sensitivity and specificity. The best performance results on the OEG dataset were obtained in the data sharing scenario of 80% training and 20% validation, with sensitivity values of 81%, specificity 76%, ROC-AUC 79%, PR-AUC 82%. The best results on the CEG dataset were obtained from dividing 80% training data and 20% validation data with values obtained for sensitivity 73%, specificity 50% ROC-AUC 61%, and PR-AUC 45%

Keyword : Gen Essential, Classification, *Drosophila melanogaster*, Protein sequence, LSTM.