

Evaluasi KNN dalam Kategorisasi Musik Latar Game

Harits Ar Rosyid¹, Agusta Rakhmat Taufani², Tenty Luay Sari³

1. Universitas Negeri Malang, Indonesia | harits.ar.ft@um.ac.id

2. Universitas Negeri Malang, Indonesia | agusta.rakhmat.ft@um.ac.id

3. Universitas Negeri Malang, Indonesia | tenty.luay.1705356@students.um.ac.id

Abstrak

Musik berkontribusi untuk membuat *immersive atmosphere* untuk bermain game dan dapat secara efektif mendorong aksi pada layar. Maka dari itu memilih musik latar pada sebuah game merupakan hal yang tidak mudah, karena memilih musik yang cocok untuk sebuah game merupakan sebuah tantangan. Setiap genre game membutuhkan musik latar yang tepat sehingga dapat membangun suasana antara pemain dengan game itu sendiri, sehingga pemain berempati terhadap setiap aksi yang dilakukan dalam sebuah game, Karena keunikan dari karakteristik pada setiap platform game membutuhkan musiknya sendiri. Maka dari itu digunakan Machine Learning untuk melakukan otomatisasi pengenalan genre pada musik. Dengan menggunakan Algoritma K-Nearest Neighbors untuk menentukan genre yang tepat serta Agglomerative Clustering untuk mengetahui seberapa berkaitannya satu genre dengan genre yang lain, sehingga dapat mengetahui genre musik yang bersesuaian dengan genre game. Hasil yang didapatkan dari penelitian ini ialah 1) Hasil dari klasifikasi dengan menggunakan k-Nearest Neighbors menunjukkan hasil yang rendah hanya mencapai tingkat akurasi sebesar 51,3%, 2) Hasil dari clustering yang dilakukan oleh *Agglomerative Nesting* menghasilkan 3 kluster besar dari 8 genre yang dijadikan sebagai acuan, ini menandakan bahwa dalam 8 genre yang diuji cobakan, kemungkinan dalam satu genre tidak murni hanya menggunakan satu genre saja melainkan campuran dari beberapa genre sehingga hanya menghasilkan 3 genre besar 3) hasil validasi dengan menggunakan Agglomerative clustering juga menunjukkan beberapa genre masuk kedalam beberapa kluster sehingga mendukung dari poin sebelumnya bahwa genre yang digunakan pada musik latar game tidak murni hanya dengan satu genre saja. Namun dari hasil kluster dapat diketahui karakteristik dari setiap kluster yaitu kluster 0 memiliki irama yang keras, kluster 1 memiliki irama yang tidak begitu keras namun tidak begitu menenangkan sementara itu untuk kluster 2 memiliki irama yang menenangkan. Kemudian Adapun perbedaan dari hasil distribusi pada data uji dan hasil prediksi dikarenakan oleh rendahnya tingkat akurasi dari prediksi yang sudah dilakukan.

Kata Kunci

Musik Latar, Game, k-nearest neighbors, agglomerative clustering

1. Pendahuluan

Game komputer secara aktif dinikmati oleh jutaan orang diseluruh dunia. Dengan berbagai macam variasi pada desain grafis dan juga genre yang digunakan, Namun *game* komputer semuanya memiliki satu elemen penting yang sama yaitu memiliki kemampuan berupa daya tarik, yaitu dimana dalam suatu momen, hampir seluruh perhatiannya terfokuskan pada *game*, Pengalaman ini sering kali disebut dengan “*immersion*”, yaitu merupakan istilah yang digunakan oleh pemain dan peninjau *game* (Jennett et al., 2008).

Apapun *game* populer saat ini harus mengarah pada pengalaman *immersive gameplay* yang dapat berpengaruh kuat pada tindakan dan juga perhatian dari pemain (Xiaoqing Fu, 2015). Untuk mendapatkan pengalaman tersebut digunakan Musik latar pada *game*. Musik latar atau yang biasa disebut dengan *background music* mengacu pada semua suara (termasuk musik dan efek suara) yang muncul dalam video *game* dan merupakan bagian yang tidak terpisahkan dari video *game* modern. Musik latar ini digunakan sebagai media komunikasi, yaitu penyampaian narasi dan membangkitkan emosi serta memperdalam pengalaman pemain. Musik latar ini bergantung dengan Genre yang digunakan pada *game* (Xiaoqing Fu, 2015).

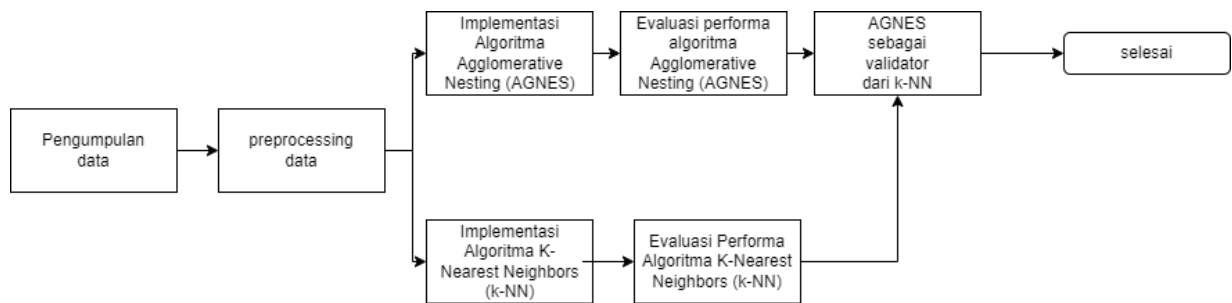
Maka diperlukan otomatisasi klasifikasi genre musik latar pada *game*, karena Pada saat ini banyaknya musik latar yang beredar di internet. Genre yang ditentukan oleh pencipta musik merupakan referensi yang baik bagi pengembangan *game*. Sedangkan karakteristik musik latar ini tidak mudah dipelajari secara *manual* oleh manusia. Solusinya adalah dengan menerapkan teknik data mining, yaitu klasifikasi. Harapannya dengan mengetahui karakteristik musik latar pada tiap genre, maka akan memudahkan pengembang *game* dalam menentukan musik latar yang lebih sesuai. Klasifikasi merupakan suatu proses pemasukkannya sejumlah objek data kedalam kelas yang tersedia (Thi Bi Dan, Widya Sihwi, dan Anggrainingsih, 2016). Pada penelitian ini digunakan *k-Nearest Neighbors* (k-NN) untuk melakukan klasifikasi. k-NN merupakan algoritma yang berbasis pembelajaran terbimbing berbasis jarak. k-NN memiliki atribut *k* yaitu jumlah tetangga pada klasifikasi dengan menggunakan bilangan bulat yang kecil, serta positif dan juga ganjil (Andrian et al., 2019). Dengan mengetahui klasifikasi dari genre pada musik latar *game* tidaklah cukup, Karena menurut Caesar, 2015 dalam satu musik pada musik latar dapat memuat beberapa genre yang digabungkan. Diharapkan dengan teknik klusterisasi dapat mengetahui relasi antar genre, sehingga dapat diketahui genre mana saja pada musik latar yang memiliki relasi terdekat. Klusterisasi ini dilakukan menggunakan algoritma *Agglomerative Nesting* atau AGNES. AGNES merupakan algoritma yang menggunakan pendekatan “*bottom-up*” pada kluster hierarikal.

Maka dari itu, dengan karakteristik yang dimiliki oleh kedua algoritma tersebut diharapkan dapat meningkatkan ketepatan dari genre musik yang digunakan pada genre musik latar pada *game*.

2. Metode

a. Alur kerja penelitian

Penelitian ini bertujuan untuk merancang Kategorisasi Musik Latar *Game* menggunakan Kombinasi *K-Nearest Neighbors* dan *Agglomerative Clustering*. Adapun Langkah-langkah pengerjaan dari penelitian ini terdapat pada , yaitu :



Gambar 1. Rancangan Alur Penelitian

Pada penelitian ini dilakukan secara bertahap dengan acuan pada rancangan alur penelitian dari Gambar 1, yaitu 1) Dimana data akan dikumpulkan sebanyak 240 sampel musik latar yang dibagi kedalam 8 genre, 2) praproses dilakukan untuk mengubah data menjadi data yang mudah digunakan pada algoritma dengan menggunakan transformasi data, 3) implementasi dari algoritma k-NN dan AGNES diproses untuk mendapatkan hasil klasifikasi dan juga klusterisasi, 4) dilakukan evaluasi dari kedua algoritma, 5) Selanjutnya hasil dari prediksi k-NN akan digunakan sebagai data untuk divalidasi oleh AGNES

3. Hasil dan Pembahasan

A. Hasil Pengumpulan Data

Pada penelitian ini menggunakan 240 dataset dengan format wav, yang dibagi kedalam 8 genre music yaitu : 1) Chiptune, 2) Country, 3) Horror, 4) Jazz, 5) Medieval, 6) Metalcore, 8) Synthwave. Dengan masing-masing genre memiliki sebanyak 30 dataset dengan durasi 30 detik pada setiap dataset yang dimiliki. Dalam penelitian ini digunakan fitur *short-time* dikarenakan menggunakan nilai *Mel-frequency cepstral coefficients* (MFCC), yang mengutamakan kuantitas pada turunan spektrum dalam segmen pendek seperti frame pada potongan musik (Chang et al., 2010), sehingga tidak dibutuhkan segmentasi dari musik yang panjang karena hanya akan digunakan 13 nilai MFCC. Hal ini dikarenakan koefisien MFCC 8-13 pertama digunakan untuk mewakili bentuk dari spektrum (Gutiérrez et al., 2006).

B. Hasil Preprocessing Data

Proses ini merupakan tahap awal yang dilakukan, yang digunakan untuk mempermudah proses yang dilakukan pada sistem dengan mengubah data atau disebut transformasi (Nasution et al., 2019). Dengan tujuan, menyeragamkan setiap fitur pada data (Singh and Singh, 2020). Proses transformasi data yang pertama akan dilakukan dengan cara mengubah data yang masih berupa sinyal suara dalam format wav akan diubah menjadi nilai cepstrum ke dalam bentuk matrix

dengan menggunakan *Jupyter Notebook*, memakai *package* librosa. Librosa merupakan *package* pada python untuk musik dan analisis suara. *package* ini menyediakan fungsi yang diperlukan untuk membuat sistem pencarian informasi pada musik (Raguraman et al., 2019). Pada tahap ini dilakukan 2 kali transformasi data, yaitu :

1. Transformasi data wav menjadi nilai fitur pada domain waktu dan frekuensi

Penentuan dari atribut musik yang digunakan pada penelitian ini mengacu pada dataset dari GTZAN. Dataset GTZAN sebelumnya sudah banyak digunakan pada penelitian identifikasi genre musik dan dipertahankan validitasnya (Ceylan et al., 2021). Tujuan dari ekstraksi fitur ialah untuk mengubah bentuk gelombang sinyal suara menjadi beberapa atribut sebagai representasi untuk dilakukan analisis dan pemrosesan sinyal lebih lanjut.

Fitur Musik	data ke-1	Fitur Musik	data ke-1	Fitur Musik	data ke-1
chroma_stft_mean	0.311225	mfcc2_mean	70.74883	mfcc11_var	78.36073
chroma_stft_var	0.084367	mfcc2_var	127.4264	mfcc12_mean	-2.26121
rms_mean	0.182074	mfcc3_mean	15.60785	mfcc12_var	111.8802
rms_var	0.002772	mfcc3_var	56.36179	mfcc13_mean	-8.49868
spec_cent_mean	2191.648	mfcc4_mean	41.08438	mfcc13_var	90.13553
spec_cent_var	122826.6	mfcc4_var	41.6947	mfcc14_mean	0.27276
spec_bw_mean	2594.306	mfcc5_mean	8.570517	mfcc14_var	48.25702
spec_bw_var	9378.573	mfcc5_var	31.42961	mfcc15_mean	-4.77482
rolloff_mean	5220.478	mfcc6_mean	21.26035	mfcc15_var	98.56172
rolloff_var	327810.8	mfcc6_var	33.99697	mfcc16_mean	1.73479
zcr_mean	0.055641	mfcc7_mean	4.234947	mfcc16_var	94.86993
zcr_var	0.000364	mfcc7_var	26.83381	mfcc17_mean	-8.94358
harmony_mean	-1.12E-05	mfcc8_mean	10.01602	mfcc17_var	118.2251
harmony_var	0.019424	mfcc8_var	43.12484	mfcc18_mean	-5.19935
percept_mean	0.000103	mfcc9_mean	-4.07815	mfcc18_var	91.92432
percept_var	0.009402	mfcc9_var	79.3603	mfcc19_mean	-4.51594
tempo	117.4538	mfcc10_mean	2.065836	mfcc19_var	58.24217
mfcc1_mean	-23.2774	mfcc10_var	63.54193	mfcc20_mean	5.566433
mfcc1_var	1913.119	mfcc11_mean	-10.3017	mfcc20_var	72.99714

Gambar 2. Contoh hasil transformasi data pada durasi 10 detik

2. Normalisasi Data

Pada tahap ini dilakukan normalisasi. Normalisasi data merupakan metode yang dilakukan pada data mentah yang akan di skala ulang (Han et al., 2012) dari nilai fitur yang sudah didapatkan sebelumnya sehingga tidak ada ketimpangan data yaitu terdapat nilai yang terlalu tinggi maupun terlalu rendah dengan menggunakan normalisasi min-max.

Nama Atribut Musik	data ke-1	Nama Atribut Musik	data ke-1	Nama Atribut Musik	data ke-1
chroma_stft_mean	0.289048	mfcc2_mean	0.311745	mfcc11_var	0.134491
chroma_stft_var	0.503373	mfcc2_var	0.014795	mfcc12_mean	0.455153
rms_mean	0.446769	mfcc3_mean	0.709861	mfcc12_var	0.27762
rms_var	0.056574	mfcc3_var	0.011946	mfcc13_mean	0.506509
spec_cent_mean	0.593488	mfcc4_mean	0.713391	mfcc13_var	0.180941
spec_cent_var	0.036433	mfcc4_var	0.019945	mfcc14_mean	0.556093
spec_bw_mean	0.770921	mfcc5_mean	0.657383	mfcc14_var	0.121476
spec_bw_var	0.003985	mfcc5_var	0.030594	mfcc15_mean	0.479476
rolloff_mean	0.670526	mfcc6_mean	0.71658	mfcc15_var	0.231901
rolloff_var	0.032209	mfcc6_var	0.047443	mfcc16_mean	0.474449
zcr_mean	0.239917	mfcc7_mean	0.804002	mfcc16_var	0.185787
zcr_var	0.012224	mfcc7_var	0.053404	mfcc17_mean	0.215766
harmony_mean	0.847642	mfcc8_mean	0.71424	mfcc17_var	0.218099
harmony_var	0.168446	mfcc8_var	0.090559	mfcc18_mean	0.434753
percept_mean	0.594845	mfcc9_mean	0.562089	mfcc18_var	0.223427
percept_var	0.184446	mfcc9_var	0.127793	mfcc19_mean	0.578653
tempo	0.447811	mfcc10_mean	0.424222	mfcc19_var	0.126938
mfcc1_mean	0.737118	mfcc10_var	0.110895	mfcc20_mean	0.787981
mfcc1_var	0.062514	mfcc11_mean	0.479077	mfcc20_var	0.164139

Gambar 3. Contoh hasil normalisasi data pada durasi 10 detik

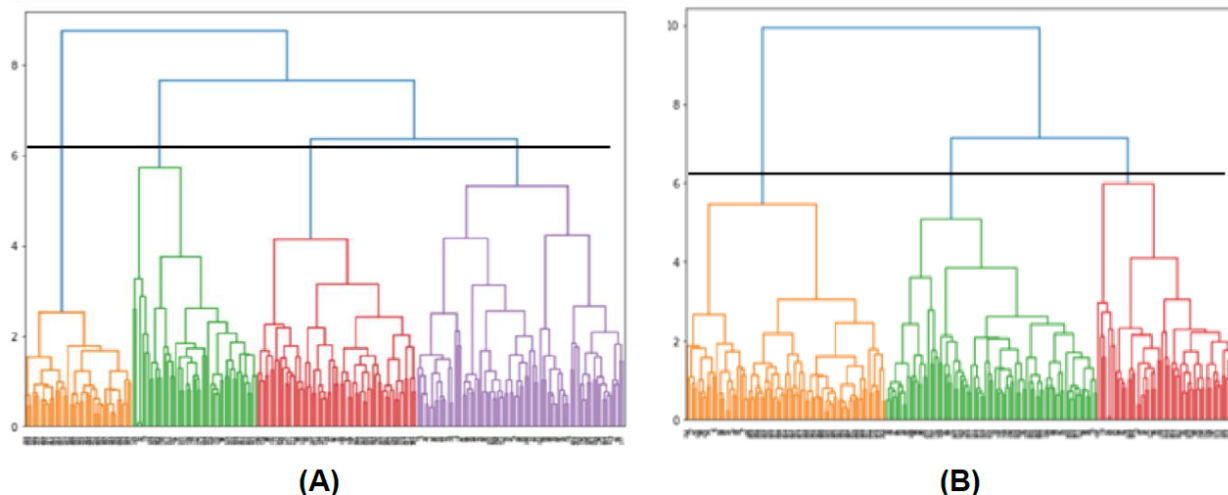
3. Hasil Implementasi Algoritma *k-Nearest Neighbors*

Data dibagi menjadi data uji dan data latih. Pada penelitian ini akan digunakan *10 Fold Stratified Kfold* untuk melakukan pembagian data. Pada *stratified cross validation* ini *fold* didistribusikan dari setiap kelas yang ada dengan pembagian kira-kira sama (Han et al., 2012). Sehingga setiap *fold* yang terbentuk memiliki data yang mewakili dari setiap genre. Secara umum metode ini direkomendasikan karena biasanya yang rekatif rendah (Larose, 2015). Kemudian perlu dilakukan uji coba untuk mengetahui nilai *k* yang menghasilkan akurasi paling tinggi. Nilai *k* itu sendiri menjelaskan berapa banyak jumlah neighbor atau data terdekat dari sebuah objek (Angreni et al., 2019). Dengan uji coba *k* sebanyak 40 kali dapat diketahui bahwa pada durasi 10 detik maupun durasi 20 detik memiliki tingkat akurasi yang sama yaitu sebesar 48,3%. Sementara untuk *f-score* pada 10 detik sebesar 44% dan pada durasi 20 detik sebesar 43%. Akurasi menunjukkan probabilitas nilai sebenarnya dari label kelas untuk memperkirakan efektivitas keseluruhan dari algoritma (Sokolova et al., 2006). Dengan kata lain efektivitas yang didapatkan dari algoritma *k-NN* untuk penelitian ini sebesar 48,3%. Untuk visualisasi hanya digunakan *f-score* dan akurasi dikarenakan nilai *f-score* merupakan kalkulasi dari *precision* dan juga *recall*.

4. Hasil Implementasi Algoritma *Agglomerative Nesting*

Hasil dari implementasi berupa dendrogram yang menyediakan rangka visual untuk menentukan ambang batas pada klaster (Tseng and Tsay, 2013). Dengan metode *ward* dan juga

jarak *Euclidean* untuk mengetahui jumlah kluster yang akan dibentuk pada tahap *clustering* dapat dilihat pada gambar berikut :



Gambar 4. Hasil Dendrogram dengan menggunakan *Agglomerative Nesting*

Penelitian dilakukan dengan menggunakan garis batas hitam untuk menentukan kluster yang dibangun. Penentuan tersebut dilakukan oleh penulis berdasarkan pengelompokan *bottom-up* dimana pada garis tersebut merupakan batas atas dari dissimilarity dari setiap kluster. Pada gambar 5 bagian A merupakan hasil pada durasi 10 detik dengan 4 kluster, sementara itu pada gambar 6 bagian B merupakan hasil pada durasi 20 detik dengan 3 kluster. Pengelompokan optimal ditentukan berdasarkan ambang batas yang mengarah pada tingkat terbaik dari silhouette score.


5. *Agglomerative Nesting* sebagai Validator pada *k-Nearest Neighbors*

A. Perhitungan Silhouette Score

Setiap kluster diwakili dengan siluet berdasarkan perbandingan dari kepadatan dan kerenggannya, dimana objek terletak baik dalam kluster maupun hanya diantara beberapa kluster (Rousseeuw, 1987). Perhitungan dilakukan dengan rata-rata jarak antara suatu objek dan semua objek lain dalam cluster dan jarak rata-rata minimum dari sebuah objek ke semua cluster lainnya (Suyatno, 2017). Hasil dari perhitungan *silhouette coefficient* mendapatkan hasil 0.279 pada durasi 20 detik sementara pada durasi 10 detik sebesar 0.269 dimana apabila hasil yang didapatkan tidak mendekati nilai 1 melainkan mendekati 0 yang menunjukkan bahwa data terdapat pada kluster yang lainnya (Shahapure dan Nicholas, 2020).

B. Penentuan Kluster Terbaik yang Terbentuk

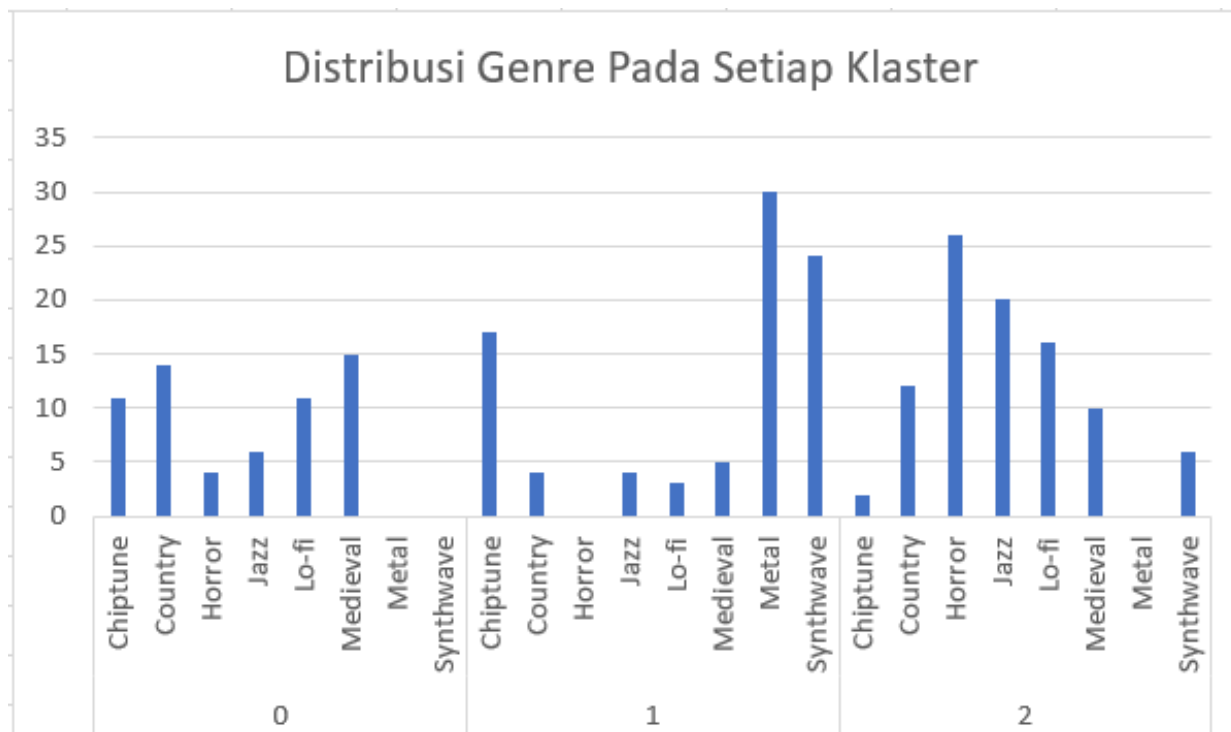
Pada tahap ini dilakukan visualisasi dari dendrogram yang sudah terbentuk untuk mengetahui persebaran dari setiap kluster, dengan hasil sebagai berikut :



Gambar 5. Hasil persebaran data pada durasi 10 detik

Dari pengelompokan berdasarkan atribut pada musik, dapat diambil kesimpulan bahwa :

- pada kluster 0 menunjukkan untuk genre medieval yang tertinggi dan jazz serta lo-fi menunjukkan posisi kedua dikarenakan memiliki jumlah data yang sama serta metal dengan genre terendah
- pada kluster 1 menunjukkan yang tertinggi ialah lo-fi dan medieval dengan jumlah nilai yang sama serta chiptune untuk genre terendah
- pada kluster 2 menunjukkan chiptune untuk genre tertinggi kemudian disusul oleh country dengan medieval dan metal pada posisi terakhir dengan 0 data
- pada kluster 3 hanya ada metal dan synthwave dengan metal yang tinggi disusul dengan synthwave.



Gambar 6. Hasil persebaran data pada durasi 20 detik

Dari pengelompokkan berdasarkan atribut pada musik, dapat diambil kesimpulan bahwa :

- pada klaster 0 di dominasi oleh medieval dan country, dengan genre medieval yang tertinggi dengan 15 data serta metal dan synthwave yang terendah dengan tidak ada data sama sekali.
- pada klaster 1 di dominasi oleh metal dan synthwave, dengan genre metal yang tertinggi dan horror yang terendah
- pada klaster 2 didominasi oleh Horror dan jazz, dengan genre horror yang tertinggi serta metal yang terendah.

Dari klaster tersebut dapat diketahui bahwa ada beberapa genre yang memiliki kesamaan satu sama lain sehingga mendominasi dalam klaster tersebut dan juga dalam setiap genre masih tidak terpusat pada satu klaster melainkan tersebar pada beberapa klaster. Hal ini dikarenakan dalam satu musik pada musik latar dapat memuat beberapa genre yang digabungkan (Caesar, 2015). hal ini ditunjukkan dari hasil silhouette score yang mendekati 0. Dari penelitian yang sudah dilakukan oleh keduanya, dapat disimpulkan bahwa dari kedua klaster untuk durasi 20 detik memiliki *silhouette score* lebih tinggi dikarenakan densitas dari klaster yang terbentuk lebih kecil sehingga dapat disimpulkan bahwa kepadatan genre dalam memenuhi sebuah klaster lebih baik.

4. Kesimpulan

Evaluasi KNN dalam kategorisasi Musik Latar Game menunjukkan beberapa hasil kesimpulan dalam penelitian yang sudah dilakukan. Antara lain: 1) Klasifikasi menggunakan k-Nearest Neighbors menunjukkan hasil yang sama pada durasi 10 dan 20 detik yaitu mencapai tingkat akurasi sebesar 48,3% namun untuk f-scorenya pada durasi 10 detik sebesar 44,7% sementara pada durasi 20 detik sebesar 43,7%, 2) Hasil dari clustering yang dilakukan oleh *Agglomerative Nesting* menghasilkan 4 klaster pada durasi 10 detik dan 3 klaster pada 20 detik, 3) hasil validasi dengan menggunakan *Agglomerative clustering* juga menunjukkan pada durasi 20 detik memiliki kepadatan antar klaster pada durasi 20 detik lebih tinggi dibandingkan pada durasi 10 detik.

Daftar Rujukan

- Andrian, R., Naufal, M.A., Hermanto, B., Junaidi, A., Lumbanraja, F.R., 2019. k-Nearest Neighbor (k-NN) Classification for Recognition of the Batik Lampung Motifs. *J. Phys.: Conf. Ser.* 1338, 012061. <https://doi.org/10.1088/1742-6596/1338/1/012061>
- Angreni, I.A., Adisasmitha, S.A., Ramli, M.I., Hamid, S., 2019. PENGARUH NILAI K PADA METODE K-NEAREST NEIGHBOR (KNN) TERHADAP TINGKAT AKURASI IDENTIFIKASI KERUSAKAN JALAN. *JRS* 7, 63. <https://doi.org/10.22441/jrs.2018.v07.i2.01>
- Caesar, R., 2015. Kajian Pustaka Perkembangan Genre Games Dari Masa Ke Masa 1, 22.
- Ceylan, H.C., Hardalaç, N., Kara, A.C., Hardalaç, F., 2021. Automatic Music Genre Classification and Its Relation with Music Education. *WJE* 11, 36. <https://doi.org/10.5430/wje.v11n2p36>
- Han, J., Kamber, M., Pei, J., 2012. Introduction, in: *Data Mining*. Elsevier, pp. 1–38. <https://doi.org/10.1016/B978-0-12-381479-1.00001-0>
- Jennett, C., Cox, A.L., Cairns, P., Dhoparee, S., Epps, A., Tijs, T., Walton, A., 2008. Measuring and defining the experience of immersion in games. *International Journal of Human-Computer Studies* 66, 641–661. <https://doi.org/10.1016/j.ijhcs.2008.04.004>
- Larose, D.T., 2015. *Discovering Knowledge in Data: An Introduction to Data mining*. John Wiley and Sons, Inc.
- Nasution, D.A., Khotimah, H.H., Chamidah, N., 2019. Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Com, Engine, Sys, Sci* 4, 78. <https://doi.org/10.24114/cess.v4i1.11458>
- Raguraman, P., R., M., Vijayan, M., 2019. LibROSA Based Assessment Tool for Music Information Retrieval Systems, in: *2019 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*. Presented at the 2019 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR), IEEE, San Jose, CA, USA, pp. 109–114. <https://doi.org/10.1109/MIPR.2019.00027>
- Rousseeuw, P.J., 1987. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics* 20, 53–65. [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Shahapure, K.R., Nicholas, C., 2020. Cluster Quality Analysis Using Silhouette Score, in: *2020 IEEE 7th International Conference on Data Science and Advanced Analytics (DSAA)*. Presented at the 2020 IEEE 7th International Conference on Data Science and Advanced

- Analytics (DSAA), IEEE, sydney, Australia, pp. 747–748.
<https://doi.org/10.1109/DSAA49011.2020.00096>
- Singh, D., Singh, B., 2020. Investigating the impact of data normalization on classification performance. *Applied Soft Computing* 97, 105524.
<https://doi.org/10.1016/j.asoc.2019.105524>
- Singha, A., Ullah, M.A., 2022. Development of an audio watermarking with decentralization of the watermarks. *Journal of King Saud University - Computer and Information Sciences* 34, 3055–3061. <https://doi.org/10.1016/j.jksuci.2020.09.007>
- Sokolova, M., Japkowicz, N., Szpakowicz, S., 2006. Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation, in: Sattar, A., Kang, B. (Eds.), *AI 2006: Advances in Artificial Intelligence, Lecture Notes in Computer Science*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 1015–1021.
https://doi.org/10.1007/11941439_114
- Suyatno, 2017. *Data Mining Untuk Klasifikasi dan Klasterisasi Data*. Informatika, Bandung, Indonesia.
- Thi Bi Dan, T., Widya Sihwi, S., Anggrainingsih, R., 2016. IMPLEMENTASI ITERATIVE DICHOTOMISER 3 PADA DATA KELULUSAN MAHASISWA S1 DI UNIVERSITAS SEBELAS MARET. *ITSmart* 4, 84. <https://doi.org/10.20961/its.v4i2.1770>
- Tseng, Y.-H., Tsay, M.-Y., 2013. Journal clustering of library and information science for subfield delineation using the bibliometric analysis toolkit: CATAR. *Scientometrics* 95, 503–528.
<https://doi.org/10.1007/s11192-013-0964-1>
- Xiaoqing Fu, J.Z., 2015. The Influence of Background Music of Video Games on Immersion. *J Psychol Psychother* 05. <https://doi.org/10.4172/2161-0487.1000191>