

# SISTEM PENCADANG PRODUK KOSMETIK MENGGUNAKAN PEMBELAJARAN MESIN

Arvind Naido A/L Thirumoorty & Dr. Lailatul Qadri Binti Zakaria

*Fakulti Teknologi & Sains Maklumat, Universiti Kebangsaan Malaysia, 43600 UKM Bangi,,  
Selangor Darul Ehsan, Malaysia*

## Abstrak

Sebelum pandemik COVID-19, produk kosmetik secara amnya akan disyorkan oleh pakar dermatologi dan jurujual yang berpengetahuan tentang keperluan pelanggan serta keadaan kulit. Walaubagaimanapun, Perintah Kawalan Pergerakan (PKP) yang dilaksanakan oleh kerajaan Malaysia telah menyebabkan syarikat-syarikat kosmetik menukar model perniagaan mereka kepada dalam talian. Pelanggan akan membeli produk kosmetik berdasarkan ulasan dan penilaian produk yang diberi oleh pelanggan lain. Untuk menangani cabaran ini, sistem pencadang telah dibangunkan bagi mencadang produk kosmetik berdasar pilihan pengguna dan item yang serupa. Projek ini menerangkan proses pembangunan sistem pencadang produk kosmetik dengan menggunakan set data produk kosmetik daripada laman web Sephora, memfokuskan kepada pelbagai model pencadang dan teknik. Kajian ini meneroka dua model populariti iaitu model populariti kekerapan penilaian, model populariti penarafan berwajaran, tiga model penapisan berasaskan kandungan (PBK) iaitu dengan menggunakan CountVectorizer, TF-IDF dan Word2Vec, lima model penapisan kolaboratif (PK) termasuklah PK berasaskan pengguna, PK berasaskan item, PK dengan pakej Surprise, PK dengan pakej LightFM dan penapisan kolaboratif neural (NCF). Projek ini melibatkan beberapa fasa, termasuk mengikis laman web Sephora untuk mengumpulkan set data, pembersihan data, pra-pemprosesan data, mengenal pasti produk popular, penapisan berasaskan kandungan, kaedah penapisan kolaboratif dan penjanaan cadangan produk kosmetik. Analisis sentimen dilakukan menggunakan teknik pemprosesan bahasa tabii dijalankan selepas pra-pemprosesan data. Sistem pencadang dan antara muka yang berhasil dilaksanakan melalui aplikasi berasaskan web menggunakan Streamlit. Dengan menawarkan cadangan produk kosmetik yang diperbadikan, sistem ini bertujuan untuk membantu pelanggan menjimatkan masa dan membuat keputusan pembelian yang termaklum. Hasil kajian mendapat bahawa model PBK Word2Vec mempunyai prestasi paling tinggi berbanding CountVectorizer dan TF-IDF. Model PK berasaskan item juga mempunyai penilaian terbaik dari segi penilaian RMSE dan MAE. Dengan merapatkan jurang antara perundingan dalam kedai dan beli-belah dalam talian, projek ini memberi kuasa kepada pengguna untuk mengakses cadangan produk kosmetik yang sesuai dengan mudah berdasarkan pilihan mereka dan penggunaan produk terdahulu.

**Kata kunci:** Sistem Pencadang, Pembelajaran Mesin.

## Pengenalan

Produk kosmetik biasanya merujuk kepada produk solek seperti pemerah pipi, pembayang mata dan gincu untuk menjadikan seseorang kelihatan cantik. Di peringkat kawalan regulatori, kosmetik mempunyai definisi yang lebih terperinci dan jelas iaitu bahan atau sediaan untuk digunakan pada bahagian luaran badan manusia seperti kulit, rambut, kuku, bibir, bahagian luaran organ genital manusia, gigi atau membran mukus di dalam mulut yang bertujuan untuk membersih, mewangi, mengubah penampilan, menghilangkan bau badan, melindungi dan mengekalkan badan dalam keadaan baik. Produk kosmetik tidak hanya merujuk kepada gincu, bedak muka, maskara malah ia merangkumi lain-lain produk penjagaan pembersihan diri seperti syampu, sabun badan dan produk penjagaan gigi. Justeru, produk kosmetik bukan sahaja terhad kepada gincu atau bedak padat tetapi juga produk penjagaan diri seperti sabun, syampu dan produk penjagaan mulut (KKM 2019).

Sistem pencadang atau sistem pengesyorkan (SP) ialah sistem yang direka untuk mengesyorkan sesuatu produk kepada pengguna berdasarkan beberapa faktor yang berbeza. Sistem ini biasanya melibatkan jumlah maklumat yang besar dengan menapis ciri-ciri yang paling penting berdasarkan data yang diberikan oleh pengguna dan faktor lain berdasarkan keutamaan dan minat pengguna. Sistem pencadang dapat mengenal-pasti padanan dan persamaan antara pengguna dan produk dan akhirnya membuat cadangan produk (Dwivedi 2020).

Sistem pencadang, seperti yang ditakrifkan di atas, berada di bawah kategori sistem penapisan maklumat dan bertujuan untuk meramalkan penilaian atau keutamaan yang mungkin ditetapkan oleh pengguna kepada item. Setelah ramalan dibuat, sistem menjana cadangan atau cadangan berdasarkan hasil ramalan. Walaupun konsep itu mungkin kelihatan mudah, kerja dalaman sistem pencadang melibatkan proses rumit yang mengawal fungsinya. Sistem pengesyoran

boleh dibina menggunakan pelbagai pendekatan, dengan setiap pendekatan disesuaikan dengan keperluan khusus aplikasi. Pendekatan ini boleh dikelaskan secara meluas kepada tiga jenis utama: Penapisan Kolaboratif (PK) iaitu Collaborative Filtering (CF), Penapisan Berasaskan Kandungan (PBK) iaitu Content based Filtering (CB) dan Sistem Pengesyoran Hibrid (Lokesh, A 2019).

Hari ini, sistem pencadang digunakan secara meluas dalam bidang komersial. Contohnya, syarikat seperti Amazon, Netflix dan Pandora telah menggunakan system pencadang untuk membantu pelanggan dan pengguna menemui item yang berkaitan. Sistem ini memainkan peranan penting dalam meningkatkan pengalaman pengguna dengan memperbaiki cadangan. Sebagai contoh, Netflix memanfaatkan kadar (rating) filem berdasarkan pengguna untuk meramalkan dan mencadangkan filem lain yang mungkin mereka nikmati. Pandora memperhalusi pilihan lagu pada setiap stesen radio dengan mempertimbangkan penilaian pengguna dan menggunakan sistem berdasarkan kandungan. Amazon, sebaliknya, mencadangkan item berkaitan berdasarkan pembelian sebelum yang dilakukan oleh pelanggan dan paparan item, serta item yang dibeli oleh pelanggan lain yang juga pernah melihat item yang sama. Dengan mengurangkankekangan carian untuk pelanggan dan membantu mereka mencari perkara yang mereka mahu, syarikat-syarikat begini menyasarkan untuk meningkatkan jualan, kepuasan dan kesetiaan pelanggan (Stomberg 2014).

### **Pernyataan Masalah**

Produk kosmetik secara lazimnya terdiri daripada pelbagai kategori yang sangat luas dan setiap satu produk mempunyai tujuan yang berbeza. Hal ini menyebabkan, pengguna terpaksa bergantung kepada proses pencarian maklumat secara manual untuk memilih produk kosmetik yang bersesuaian dengan keperluan mereka dengan membaca ulasan pengguna lain yang telah

menggunakan produk tersebut. Proses pencarian maklumat secara manual sebegini mengambil masa yang lama dan terdapat juga pengedar produk yang meletakkan ulasan-ulasan yang tidak sahih untuk mempromosikan produk mereka di laman web.

Selain itu, sewaktu pelaksanaan PKP, pelanggan tidak dapat mencuba produk secara fizikal sebelum membeli dan terpaksa bergantung sepenuhnya pada ulasan dalam talian yang boleh menjadi subjektif dan berat sebelah. Kekurangan ini dan pilihan produk kosmetik yang banyak menyukarkan pelanggan untuk mencari produk yang selaras dengan cita rasa mereka dan memenuhi keperluan penjagaan kulit yang khusus.

Untuk menangani cabaran ini, sistem pencadang dapat membantu pelanggan membuat keputusan pembelian secara termaklum. Sistem ini menggunakan keutamaan pengguna dan data sebelumnya untuk meramal dan mencadangkan produk kosmetik yang dapat menarik minat pelanggan. Walau bagaimanapun, terdapat keperluan untuk membandingkan dan menilai model dan teknik sistem pencadang yang berbeza untuk menentukan keberkesanannya dalam domain penjagaan kulit dan kosmetik.

### **Objektif Kajian**

Projek ini menggariskan tiga objektif yang utama seperti berikut:-

- a. Untuk membandingkan dan menilai pelbagai algoritma sistem pencadang, termasuklah dua model populariti iaitu model populariti kekerapan penilaian, model populariti penarafan berwajaran, tiga model PBK iaitu dengan menggunakan CountVectorizer, TF-IDF dan Word2Vec, lima model PK termasuklah PK berdasarkan pengguna, PK berdasarkan item, PK dengan pakej Surprise, PK dengan pakej LightFM dan penapisan kolaboratif neural (NCF).

- b. Untuk mengekstrak data dan ulasan produk kosmetik serta pengguna dari laman web Sephora melalui penggunaan web scrapper.
- c. Untuk mengimplementasi sistem pencadang dalam platform aplikasi berdasarkan web menggunakan Streamlit.

### **Skop Kajian**

Sistem pencadang hanya akan dapat mengesyorkan 297 produk kosmetik dengan jumlah pengguna sebanyak 7943 dan jumlah jenama produk sebanyak 74. Hanya satu model PBK, satu model PK, dan satu model populariti akan dilaksanakan dalam aplikasi berdasarkan web menggunakan Streamlit. Ulasan produk tidak akan dipergunakan dalam peramalan rating dan cadangan produk dan hanya akan dipergunakan dalam analisis sentimen atas sebab kekurangan perkakasan. SP hanya akan menggunakan lima jenis warna mata, empat kategori jenis kulit, 17 kategori masalah kulit dan 10 kategori tona kulit untuk mencari pengguna yang mempunyai ciri-ciri yang sama dan mendapatkan cadangan produk.

### **Sorotan Susastera**

Sorotan susastera ini dilakukan untuk lebih memahami pengetahuan semasa mengenai kajian yang dilakukan untuk membangunkan rangka kerja teori serta mengukuhkan metodologi yang sedia ada. Sorotan susastera ini akan menumpukan kepada kaedah penapisan SP dan perbandingan sistem yang sedia ada. Analisis kelebihan dan kekurangan daripada pelbagai kajian yang dilakukan sebelum ini mampu membantu mewujudkan SP yang lebih berkesan. Bab ini juga dapat menjelaskan domain yang digunakan oleh kajian lepas, kepentingan memilih kaedah penapisan yang betul dan menjelaskan beberapa istilah yang digunakan dalam kajian ini.

Kebelakangan ini, minat yang besar telah ditunjukkan dalam menggunakan penilaian pengguna untuk menjana sistem cadangan yang disesuaikan (Chen & Chen & Wang 2015). Ahli akademik dan syarikat industri telah mula membuat penyelidikan yang luas dan menunjukkan minat dalam pembangunan SP. Dengan mengumpul maklumat secara automatik dan menyesuaikannya secara proaktif kepada kepentingan individu, sistem sedemikian membantu dalam menguruskan maklumat (Adomavicius & Tuzhilin 2005). Lokesh, A (2019) menyatakan bahawa SP ialah alat yang memberikan cadangan kepada pengguna akhir berdasarkan kesukaan mereka atau berdasarkan pengguna yang serupa. Ini membahagikan sistem pencadang kepada dua kategori utama iaitu SP yang menggunakan penapisan berdasarkan kandungan (PBK) dan penapisan kolaboratif (PK). Namun demikian, SP merupakan salah satu domain yang sangat luas dan terdapat banyak kaedah lain yang boleh dianalisis. K. Al Fararni et al. (2020) turut memberi penjelasan kepada kaedah-kaedah lain seperti pendekatan menggunakan demografi, pendekatan sosial, dan pendekatan hibrid yang menggabungkan beberapa pendekatan dan kaedah penapisan yang berbeza.

PBK ialah satu lagi teknik penapisan yang digunakan secara meluas dan mengambil kira pilihan pengguna dan huraihan item seperti yang diuraikan oleh Putriany et al. (2019). Putriany et al. menggunakan PBK dalam kajian kerana ingin memperbaikkan produk berkaitan penjagaan kulit sebanyak mungkin terhadap kehendak pengguna. PK merupakan kaedah penapisan objek berdasarkan pandangan atau ulasan orang lain. Pada dasarnya, algoritma ini menggunakan satu siri penilaian untuk meramalkan kedudukan pengguna sasaran dan akan menetapkan nilai kepada objek. Penilaian ini termasuk semua penilaian untuk objek yang didapati oleh pengguna yang tertentu (Mohammed & Majeed 2021). Sreekala (2019) mengkaji konsep SP berasaskan populariti dengan lebih terperinci, memfokuskan secara khusus pada domain filem. Kajian itu menyerlahkan kepentingan enjin pengesyoran dalam menangani cabaran lebih maklumat dan keperluan untuk cadangan diperbaikkan berdasarkan pilihan pengguna.

Untuk membangunkan SP, Adebo (2020) menggunakan model pembelajaran mendalam yang menggunakan long short-term memory (LSTM). Bersama-sama dengan skor sentimen yang digunakan dalam rangkaian neural LSTM pembelajaran mendalam, Adebo menyatupadukan kata ulasan dan analisis istilah. Sistem pencadang penjagaan kulit berasaskan kandungan dengan mengimplementasikan penapisan berasaskan kandungan turut dicipta oleh Lee (2020) 34 menggunakan pendekatan TF-IDF. Keberkesanan model berbeza kerana, menurut Adebo (2020), lebih banyak penyelidikan diperlukan untuk membangunkan sistem pencadang untuk penapisan kandungan berasaskan kandungan. Sukar untuk membuat cadangan yang baik jika maklumat sukar dalam set data untuk dikategorikan, menurut Lee (2020), yang menunjukkan bahawa PBK hanya berfungsi untuk pengguna yang aktif. Rao et al. (2017) menyatakan bahawa ulasan teks diberikan skor kekuatan sentimen positif dan negatif jika matlamatnya adalah untuk melihat sentimen dalam teks dan bukannya keikutinan dan kekuatan teks. Kajian tersebut juga mencadangkan bahawa strategi penapisan hibrid mungkin berkebolehan mengatasi beberapa isu yang berlaku dalam SP seperti masalah permulaan sejuk dan juga kelemahan jarang. Rao & Talwar (2006) menyatakan bahawa sistem PK tidak boleh mengesyorkan item kepada seseorang yang mempunyai citara yang unik, tetapi cenderung untuk mengesyorkan item yang popular.

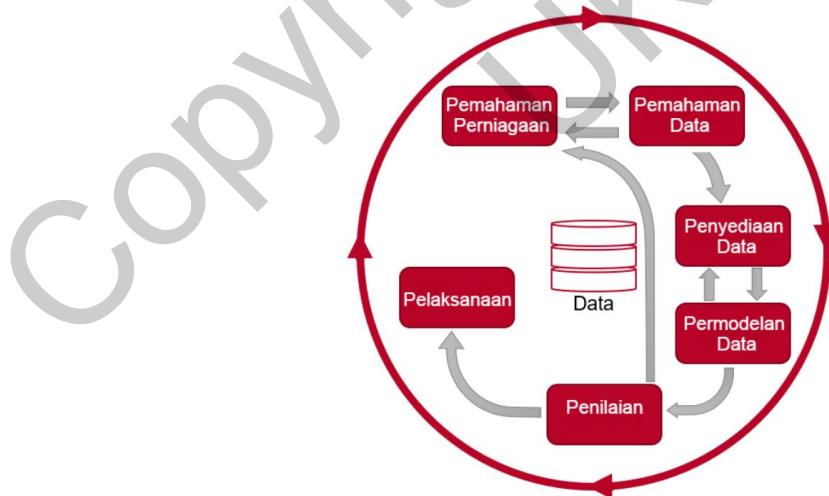
Berdasarkan kajian Madhusree Kuanr dan Puspanjali Mohapatra (2021), penilaian SP melibatkan penggunaan pelbagai kaedah penilaian untuk mengukur prestasi dan keberkesanan sistem. Kaedah penilaian bertujuan untuk menentukan ketepatan, keupayaan ramalan, perkaitan, kepelbagai, kebaharuan, kebetulan, dan aspek penting lain SP. Penilaian ramalan memberi tumpuan kepada menilai keupayaan sistem untuk meramalkan pilihan dan tingkah laku pengguna dengan tepat. Metrik seperti ketepatan, MAE, RMSE dan liputan biasanya digunakan dalam kategori ini.

Ketepatan mengukur ramalan sistem dengan penilaian pengguna sebenar, manakala MAE dan RMSE mengukur perbezaan antara penilaian yang diramalkan dan sebenar.

### Metodologi Kajian

Projek ini menggunakan metodologi Cross Industry Standard Process for Data Mining (CRISP-DM) yang sesuai untuk analisis perbandingan model pencadang kerana ia menyediakan pendekatan yang sistematik dan berulang kepada pembangunan dan penilaian model. Proses ini membolehkan penyelidik menganalisis, melaksana dan menguji prestasi algoritma yang berbeza secara menyeluruh. Dengan mengikuti metodologi CRISP-DM, projek ini boleh memastikan bahawa pelbagai model pencadang dibandingkan dan dinilai dengan betul berdasarkan kriteria yang telah ditetapkan, membolehkan pemilihan model yang tepat untuk implementasi pada sistem akhir.

Kajian ini terdiri dari enam fasa utama berdasarkan metodologi CRISP-DM.



Rajah 1.1 Metodologi CRISP-DM

a. Fasa 1: Pemahaman Perniagaan

Menggunakan pelbagai sumber untuk mendapatkan pengetahuan dan pemahaman yang menyeluruh tentang domain, objektif dan cabaran projek. Mengenal pasti titik kesakitan khusus yang dihadapi pelanggan apabila membeli-belah untuk produk kosmetik dalam talian. Pemahaman ini akan membimbing fasa projek seterusnya.

b. Fasa 2: Pemahaman Data

Menggunakan teknik mengikis web untuk mengumpul set data daripada laman web Sephora. Data yang dikumpul termasuklah nama produk, ciri pengguna seperti tona kulit, jenis kulit, warna mata dan masalah kulit, serta interaksi pengguna seperti pembelian dan ulasan produk. Melakukan analisis data penerokaan untuk mendapatkan pandangan tentang data yang tersedia dan memahami kualiti dan kaitannya dengan masalah yang dihadapi. Melakukan analisis sentimen atas ulasan produk untuk memahami data dengan lebih lanjut.

c. Fasa 3: Penyediaan Data

Dalam fasa ini, data yang dikumpul akan menjalani pembersihan menyeluruh dan pra-pemprosesan. Ini termasuk mengeluarkan sebarang data yang tidak berkaitan atau berlebihan, mengendalikan nilai yang hilang dan memastikan ketekalan dan ketepatan. Data akan diubah dan distrukturkan agar sesuai dengan keperluan algoritma sistem pencadang yang berbeza. Sebagai contoh, nama produk akan digunakan dalam model PBK untuk mencadangkan item yang serupa. Interaksi pengguna akan dianalisis untuk model PK untuk mengenal pasti pengguna yang mempunyai cita rasa yang serupa. Selain itu, ciri pengguna akan digunakan untuk memberikan cadangan yang diperbadikan.

d. Fasa 4: Permodelan Data

Melaksanakan dan menilai pelbagai algoritma sistem pencadang dalam fasa ini iaitu dua model populariti iaitu model populariti kekerapan penilaian, model populariti penarafan berwajaran, tiga model PBK iaitu dengan menggunakan CountVectorizer, TF-IDF dan Word2Vec, lima model PK termasuklah PK berasaskan pengguna, PK berasaskan item, PK dengan pakej Surprise, PK dengan pakej LightFM dan penapisan kolaboratif neural (NCF). Setiap algoritma akan menghasilkan cadangan produk kosmetik yang tepat berdasarkan pendekatan yang berbeza. Membandingkan model untuk memilih model yang paling sesuai untuk dilaksanakan.

e. Fasa 5: Penilaian

Dalam fasa ini, prestasi model sistem pencadang yang dilaksanakan akan dinilai. Menggunakan metrik penilaian yang sesuai, seperti Min Ralat Mutlak ataupun Mean Absolute Error (MAE), Sisihan akar-min-kuasa dua iaitu Root-MeanSquare Error (RMSE) dan lain-lain metrik pengukuran, untuk menilai keberkesanan ramalan rating yang akan diberi oleh setiap pengguna dan akhirnya mendapatkan cadangan produk. Model akan dibandingkan berdasarkan prestasi mereka untuk memilih model yang sesuai bagi menyelesaikan masalah ini.

f. Fasa 6: Pelaksanaan

Setelah model SP dimuktamadkan, model-model tersebut akan digunakan dan disepadukan ke dalam aplikasi berasaskan web yang menggunakan Python sebagai bahasa pengaturcaraan utama untuk pembangunan bahagian rangka belakang. Google Collaboratory akan digunakan untuk melaksanakan dan membina model. Streamlit, rangka kerja aplikasi web untuk Python, akan digunakan untuk mencipta antara muka yang intuitif dan mesra pengguna. Aplikasi ini akan menyediakan pelanggan dengan cadangan produk kosmetik yang diperbadikan berdasarkan pilihan mereka dan penggunaan produk terdahulu.

## Keputusan dan Perbincangan

Model pencadang populariti kekerapan penilaian bergantung semata-mata pada kepopularan item untuk membuat pengesyoran. Model tersebut mengesyorkan item berdasarkan populariti mutlaknya, iaitu dalam konteks kajian ini diukur dengan bilangan kali produk kosmetik tersebut dinilai. Model ini mudah dan tidak rumit untuk dilaksanakan, tetapi ia mempunyai beberapa batasan. Ia mungkin akhirnya mengesyorkan produk kosmetik yang popular tetapi tidak semestinya yang terbaik atau paling diterima baik oleh pengguna. Selain itu, ia tidak mengambil kira kualiti atau penilaian item, yang berpotensi membawa kepada cadangan yang tidak sejajar dengan keutamaan pengguna individu.

Sebaliknya, model pencadang populariti yang menggunakan penarafan wajaran mengambil kira populariti dan penilaian pengguna. Ia menggunakan formula penarafan wajaran IMDB atau pendekatan serupa, yang menggabungkan penilaian purata item dengan bilangan penilaian yang telah diterima. Ini bermakna bukan sahaja item yang dinilai tinggi tetapi juga item yang mempunyai bilangan rating yang banyak dianggap lebih baik. Pendekatan ini cenderung untuk memaparkan item yang digemari dan digunakan secara meluas, dan memberikan pengguna pemahaman yang lebih baik tentang penerimaan keseluruhan produk yang disyorkan.

Ringkasnya, model populariti kerapan penilaian hanya memfokuskan pada metrik populariti, yang boleh menghasilkan pengesyoran generik yang mungkin tidak sepadan dengan pilihan pengguna. Sebaliknya, model pengesyoran populariti yang menggunakan penarafan wajaran IMDB menawarkan pendekatan yang lebih bernuansa, mengambil kira kualiti iaitu penilaian purata dan populariti iaitu bilangan penilaian item. Ini biasanya membawa kepada pengesyoran yang lebih

termaklum dan berkaitan, menawarkan pengguna pemahaman yang lebih baik bahawa produk yang disyorkan bukan sahaja popular tetapi juga disukai oleh sebilangan besar orang. Akibatnya, model penarafan wajaran berkemungkinan memberikan pengalaman pengguna yang unggul dan meningkatkan kepuasan pengguna berbanding model populariti yang mudah. Kedua-dua model populariti pengesyoran mudah diimplementasi dan kedua-dua model pengesyoran populariti tidak menggunakan metrik penilaian dalam proses pencadangan kerana pelaksanaan yang tidak rumit dan tidak dapat dinilai dari segi penilaian metrik eksplisit seperti RMSE dan MAE.

Jadual **Error! No text of specified style in document..1** Perbandingan countvectorizer dengan TFIDF

| Metric Penilaian | CV-KNNRegre | TFIDF-KNNRegre |
|------------------|-------------|----------------|
| Ketepatan        | 0.2963      | 0.2222         |
| Kejituhan        | 0.1627      | 0.0972         |
| Imbas Kembali    | 0.1867      | 0.1108         |
| Skor-F1          | 0.1615      | 0.0959         |
| NDCG             | 3.2885      | 3.5533         |
| Kadar-hit        | 0.1         | 0.2            |
| RMSE             | 1.4466      | 1.4530         |
| MAE              | 1.0556      | 1.111          |
| <i>R-Squared</i> | -0.6173     | -0.6316        |

Jadual 4.1 menunjukkan perbandingan antara CountVectorizer iaitu CV-KNNRegre dan TF-IDF iaitu TFIDF-KNNRegre. Model, CV-KNNRegre mempunyai ketepatan yang lebih tinggi (0.2963) berbanding TFIDF-KNNRegre (0.2222). Ini menunjukkan bahawa model berdasarkan CountVectorizer berprestasi lebih baik dari segi ketepatan keseluruhan. Kejituuan pula mewakili bahagian ramalan positif sebenar antara semua ramalan positif. CV-KNNRegre mempunyai kejituuan yang lebih tinggi (0.1627) daripada TFIDF-KNNRegre (0.0972), menunjukkan bahawa model berdasarkan CountVectorizer membuat ramalan positif palsu yang lebih sedikit. Ingat kembali, juga dikenali sebagai kepekaan atau kadar positif benar, mengukur perkadaran positif benar yang diramalkan dengan betul antara semua sampel positif sebenar. CV-KNNRegre mengatasi prestasi TFIDF-KNNRegre dalam ingatan (0.1867 lwn. 0.1108), membayangkan bahawa model berdasarkan CountVectorizer adalah lebih baik dalam mengenal pasti sampel positif. Skor F1 ialah min harmonik bagi ketepatan dan ingatan serta memberikan

keseimbangan antara kedua-dua metrik. CV-KNNRegre mempunyai skor F1 yang lebih tinggi (0.1615) berbanding TFIDF-KNNRegre (0.0959), menunjukkan prestasi keseluruhan yang lebih baik dari segi ketepatan dan penarikan balik. NDCG ialah metrik kedudukan yang menilai kualiti pengesyoran kedudukan model. Nilai NDCG yang lebih tinggi menandakan cadangan yang lebih baik. TFIDFKNNRegre menunjukkan prestasi yang lebih baik sedikit dalam NDCG (3.5533) 94 berbanding CV-KNNRegre (3.2885). Kadar Hit mengukur perkadaran pengesyoran yang dianggap relevan atau berjaya. TFIDF-KNNRegre mempunyai Kadar Hit (0.2) yang lebih tinggi berbanding CV-KNNRegre (0.1), menunjukkan bahawa model berasaskan TFIDF memberikan pengesyoran yang lebih relevan. RMSE ialah metrik regresi popular yang mengukur perbezaan antara nilai yang diramalkan dan sebenar. Kedua-dua model mempunyai nilai RMSE yang serupa, dengan TFIDF-KNNRegre lebih tinggi sedikit (1.4530) daripada CV-KNNRegre (1.4466). MAE ialah satu lagi metrik regresi yang mengira perbezaan mutlak antara nilai yang diramalkan dan sebenar. Di sini sekali lagi, kedua-dua model mempunyai nilai MAE yang serupa, dengan TFIDF-KNNRegre lebih tinggi sedikit (1.111) daripada CV-KNNRegre (1.0556). RSquared, juga dikenali sebagai pekali penentuan, mengukur sejauh mana ramalan model sesuai dengan data sebenar. Kedua-dua model mempunyai nilai R-Squared negatif, yang menunjukkan bahawa mereka berprestasi buruk dalam menangkap varians dalam data. Walau bagaimanapun, CV-KNNRegre mempunyai R-Squared negatif sedikit lebih tinggi (-0.6173) berbanding TFIDF-KNNRegre (-0.6316).

Kesimpulannya, model berasaskan CountVectorizer (CV-KNNRegre) secara amnya mengatasi model berasaskan TFIDF (TFIDF-KNNRegre) dari segi ketepatan, ketepatan, ingatan semula dan skor F1. Walau bagaimanapun, model berasaskan TFIDF menunjukkan prestasi yang lebih baik dalam NDCG dan Kadar Hit, menunjukkan keunggulannya dalam memberikan cadangan yang berkaitan. Kedua-dua model mempunyai prestasi yang sama dari segi RMSE dan MAE. Kedua-dua model mempunyai nilai R-Squared negatif, menunjukkan bahawa mereka tidak sesuai untuk menangkap varians dalam data. Mengambil kira metrik keseluruhan, jika kualiti pengesyoran menjadi kebimbangan utama, model TFIDF-KNNRegre mungkin lebih sesuai kerana prestasinya yang lebih baik dalam NDCG dan Kadar Hit. Walau bagaimanapun, jika ketepatan keseluruhan dan ketepatan ramalan adalah lebih kritikal, maka model CV-KNNRegre mungkin menjadi pilihan yang lebih sesuai.

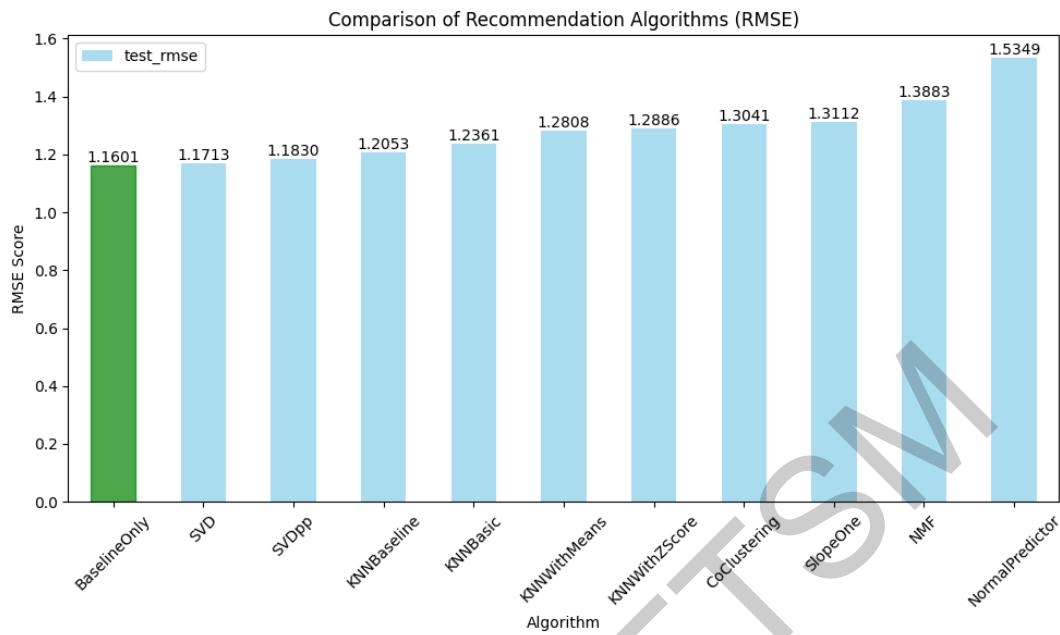
Jadual **Error! No text of specified style in document..2** Perbandingan antara ketiga-tiga model penapisan kandungan.

| <b>MODEL</b>   | <b>R-Square</b>           | <b>RMSE</b> | <b>MAE</b> |          |
|----------------|---------------------------|-------------|------------|----------|
| CV-KNNRegre    | -0.6173                   | 1.0556      | 1.4466     |          |
| TFIDF-KNNRegre | -0.6316                   | 1.4530      | 1.111      |          |
| Word2Vec       | KNeighborsRegressor       | -0.019602   | 1.14859    | 0.8704   |
|                | LinearRegression          | -0.017825   | 1.14758    | 0.871739 |
|                | BayesianRidge             | -0.0191491  | 1.14833    | 0.870713 |
|                | RandomForestRegressor     | -0.0172851  | 1.147284   | 0.872168 |
|                | GradientBoostingRegressor | -0.0184741  | 1.147954   | 0.871231 |
|                | DecisionTreeRegressor     | -0.0184741  | 1.147954   | 0.871231 |

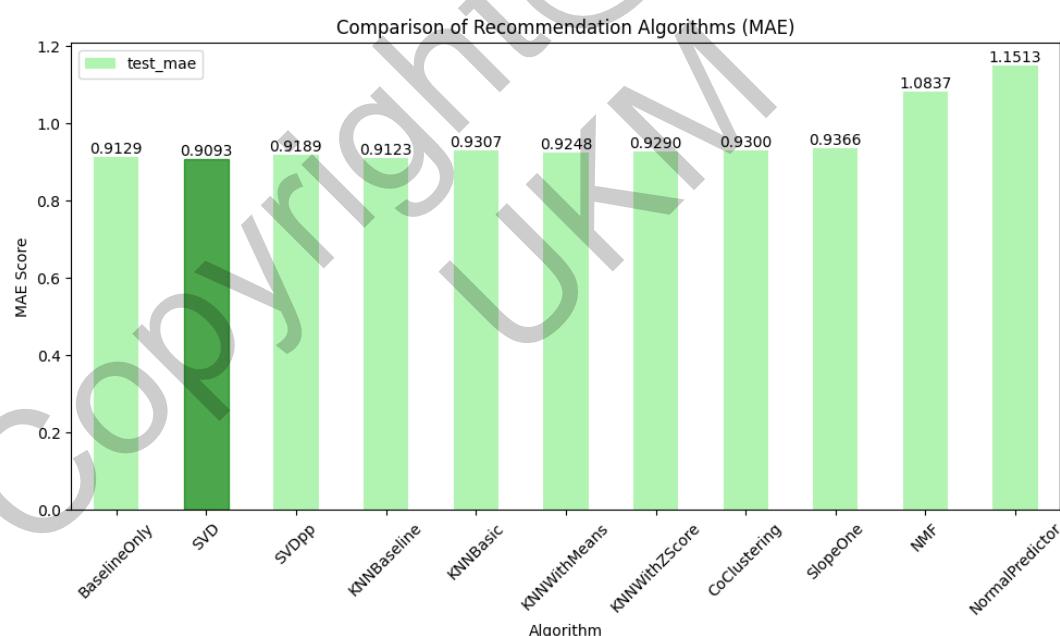
Jadual 4.2 menunjukkan perbandingan antara ketiga-tiga model PBK yang dilaksanakan. Daripada model yang disenaraikan, model Word2Vec-RandomForestRegressor mempunyai nilai R-Square yang terbaik iaitu -0.0173. Model Word2Vec-KNNRegressor mempunyai nilai MAE yang terbaik iaitu 0.8704. Model CV-KNNRegressor mempunyai nilai RMSE yang terbaik iaitu 1.0556.

|                 | <b>test_rmse</b> | <b>test_mae</b> | <b>fit_time</b> | <b>test_time</b> |
|-----------------|------------------|-----------------|-----------------|------------------|
| Algorithm       |                  |                 |                 |                  |
| BaselineOnly    | 1.160091         | 0.912852        | 0.139601        | 0.149154         |
| SVD             | 1.171289         | 0.909283        | 0.568976        | 0.113779         |
| SVDpp           | 1.182982         | 0.918947        | 0.636801        | 0.409135         |
| KNNBaseline     | 1.205343         | 0.912320        | 2.437523        | 3.768354         |
| KNNBasic        | 1.236143         | 0.930685        | 2.354617        | 3.387626         |
| KNNWithMeans    | 1.280849         | 0.924758        | 2.556362        | 3.470102         |
| KNNWithZScore   | 1.288611         | 0.928984        | 2.752528        | 3.612342         |
| CoClustering    | 1.304133         | 0.929983        | 1.855000        | 0.087452         |
| SlopeOne        | 1.311169         | 0.936620        | 0.127033        | 0.215291         |
| NMF             | 1.388307         | 1.083678        | 1.550197        | 0.194002         |
| NormalPredictor | 1.534915         | 1.151266        | 0.056154        | 0.094250         |

Rajah **Error! No text of specified style in document..1** Perbandingan penilaian model penapisan kolaboratif dalam pakej Surprise.



Rajah Error! No text of specified style in document..2 Carta perbandingan penilaian RMSE model penapisan kolaboratif dalam pakej Surprise.



Rajah Error! No text of specified style in document..3 Carta perbandingan penilaian MAE model penapisan kolaboratif dalam pakej Surprise.

Rajah 4.30 dan Rajah 4.31 menunjukkan prestasi algoritma pakej Surprise dari segi penilaian metrik RMSE dan MAE. Algoritma yang terbaik nampaknya ialah "BaselineOnly," kerana ia mempunyai nilai 'test\_rmse' dan 'test\_mae' yang paling rendah. Namun demikian, algoritma SVD berprestasi sangat rapat dengan algoritma BaselineOnly dari segi ujian RMSE

dan ujian MAE. Walaupun BaselineOnly mempunyai nilai RMSE dan MAE yang lebih rendah sedikit, prestasi SVD masih sangat kompetitif. Perbezaan dalam RMSE dan MAE antara kedua-dua model adalah agak kecil, menunjukkan bahawa SVD tidak jauh lebih teruk daripada model lain.

Jadual **Error! No text of specified style in document..3** Perbandingan lima model penapisan kolaboratif.

| Model         | RMSE                | MAE                 |
|---------------|---------------------|---------------------|
| SVD-Surprise  | 1.171               | 0.909               |
| User-Based CF | 0.7316262097357585  | 0.14158293748442832 |
| Item-based CF | 0.19572839321122615 | 0.10006110466936478 |
| LightFM       | 1.4601404760939152  | 1.2329373858981372  |
| NCF           | 1.2885              | 0.7717              |

Jadual 4.3 menunjukkan perbandingan antara lima model PK. Algoritma PK berdasarkan item berada di kedudukan teratas senarai kerana prestasinya yang luar biasa dengan nilai RMSE dan MAE terendah. Boleh dikatakan bahawa model itu cekap menangkap persamaan item dan memanfaatkan pendekatan berdasarkan kejiranian dan memberikan cadangan produk kosmetik yang sangat tepat. Keupayaannya untuk memanfaatkan perhubungan item-item memastikan pengguna menerima cadangan yang berkaitan dan diperbadikan, menjadikannya pilihan terbaik untuk SP yang dilaksanakan.

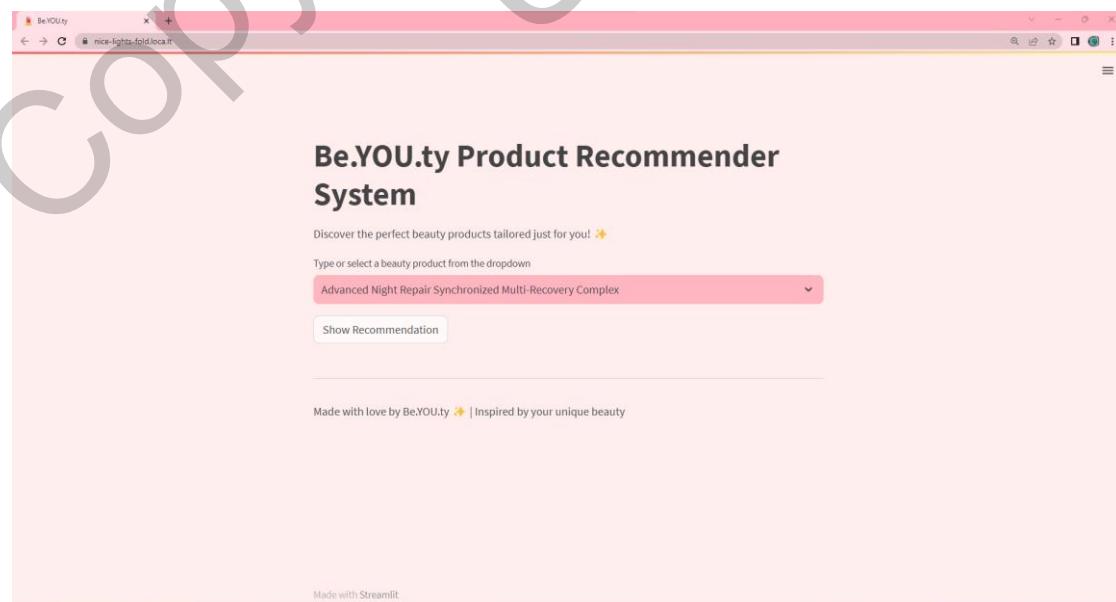
Algoritma PK berdasarkan pengguna berada di tempat kedua. Walaupun ia berprestasi mengagumkan, ia kurang berbanding model PK berdasarkan Item dari segi 99 ketepatan ramalan. Walau bagaimanapun, ia masih mengatasi beberapa model lain dalam senarai. Kaedah berdasarkan kejiranian ini berkesan dalam mengesyorkan item berdasarkan persamaan pengguna, tetapi ia mungkin dihadkan oleh interaksi item pengguna yang jarang, yang membawa kepada skor RMSE dan MAE yang lebih tinggi sedikit.

NCF, pendekatan berdasarkan pembelajaran mendalam, menduduki tempat ketiga dalam senarai. Ia mencapai prestasi kompetitif dengan markah RMSE dan MAE yang sederhana. Kelebihan NCF terletak pada keupayaannya untuk menangkap corak kompleks dan interaksi bukan linear dalam data. Walaupun ia mungkin tidak mengatasi model PK berdasarkan item

dalam penilaian ini, potensi NCF untuk menyesuaikan dan menambah baik dengan data yang lebih meluas dan penalaan hiperparameter tidak boleh dipandang remeh.

Algoritma SVD, yang dilaksanakan menggunakan Surprise, menduduki tempat keempat. Walaupun SVD ialah teknik pemfaktoran matriks yang digunakan secara meluas, prestasinya dalam penilaian khusus ini ketinggalan di belakang model berprestasi tinggi. Markah RMSE dan MAE yang lebih tinggi sedikit menunjukkan bahawa ia mungkin tidak menangkap perhubungan rumit tertentu dalam data dengan berkesan seperti model lain. Model PK menggunakan LightFM berada di kedudukan kelima dalam senarai. Walaupun ia menggabungkan pendekatan hibrid yang menggabungkan penapisan kolaboratif dan ciri berasaskan kandungan, prestasinya secara relatifnya lebih lemah berbanding dengan algoritma berprestasi tinggi. Skor RMSE dan MAE yang lebih tinggi mungkin menunjukkan bahawa penghibridan tidak menghasilkan peningkatan yang ketara dalam ketepatan ramalan untuk senario pengesyoran kosmetik tertentu ini. Algoritma PK berasaskan item muncul sebagai pilihan utama kerana ketepatan ramalan yang luar biasa dan keupayaan untuk menangkap persamaan item dengan berkesan.

Antara muka sistem pencadang produk kosmetik dibangunkan dengan menggunakan pakej Streamlit pembinaan aplikasi. Berikut merupakan implementasi sistem pencadang produk kosmetik penapisan berasaskan kandungan dalam laman web aplikasi menggunakan Streamlit.



Rajah Error! No text of specified style in document..4 Paparan antara muka untuk mendapatkan cadangan produk kosmetik berdasarkan kandungan.

**Be.YOU.ty Product Recommender System**

Discover the perfect beauty products tailored just for you! ☀️

Type or select a beauty product from the dropdown

AHA 30% + BHA 2% Peeling Solution

Show Recommendation

Here are some beauty products we think you'll love! ❤️

1. T.L.C. Sukari Babyfacial AHA + BHA Mask by Drunk Elephant ☀️
2. Caffeine Solution 5% + EGCG by The Ordinary ☀️
3. Glycolic Acid 7% Toning Solution by The Ordinary ☀️
4. Vitamin C Suspension 30% in Silicone by The Ordinary ☀️
5. Clearly Corrective Dark Spot Solution by Kiehl's ☀️
6. Watermelon + AHA Glow Sleeping Mask by Glow Recipe ☀️
7. Ready Steady Glow Daily AHA Toner by REN Clean Skincare ☀️
8. KP Bump Eraser Body Scrub with 10% AHA by First Aid Beauty ☀️
9. Watermelon Glow PHA + BHA Pore-Tight Toner by Glow Recipe ☀️
10. Violet-C Brightening Serum 20% Vitamin C + 10% AHA by Tatcha ☀️

Rajah Error! No text of specified style in document..5 Output cadangan produk kosmetik berdasarkan kandungan.

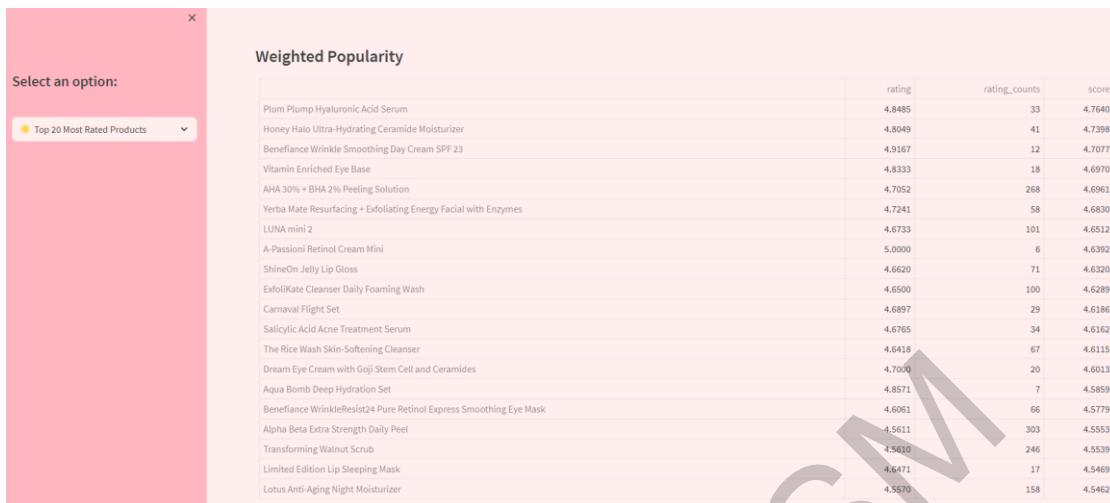
**Top 20 Most Rated Products**

Check out the most popular products:

Normal Popularity

| Product ID | Average Rating | Total Ratings | Product Name                                     | Brand Name       |
|------------|----------------|---------------|--|------------------|
| P409080    | 4.2698         | 1653          | Brazilian Bum Bum Cream                          | Sol de Janeiro   |
| P202052    | 4.3965         | 1155          | Lip Sleeping Mask                                | LANEIGE          |
| P7850      | 4.2022         | 727           | Soy Makeup Removing Face Wash                    | Fresh            |
| P37602     | 4.3939         | 655           | Super Lip Balm Sunscreen SPF 15                  | Fresh            |
| P427121    | 4.0551         | 653           | Protni Polypeptide Moisturizer                   | Drunk Elephant   |
| P7109      | 4.3317         | 618           | Purity Made Simple Cleanser                      | philosophy       |
| P392240    | 4.4924         | 589           | T.L.C. Framboos Glycolic Resurfacing Night Serum | Drunk Elephant   |
| P400259    | 3.8474         | 570           | C-Firma Vitamin C Day Serum                      | Drunk Elephant   |
| P417238    | 4.5009         | 541           | Green Clean Makeup Removing Cleansing Balm       | Farmacy          |
| P376409    | 4.1989         | 528           | SUPERMUD Charcoal Instant Treatment Mask         | GLAMGLOW         |
| P248407    | 4.4346         | 520           | Ultra Repair Cream Intense Hydration             | First Aid Beauty |
| P42343     | 4.0097         | 514           | Truth Serum                                      | OLEHENRIKSEN     |
| P218700    | 4.4258         | 512           | 100 percent Pure Argan Oil                       | Josie Maran      |
| P406712    | 4.2000         | 505           | B-Hydra Intensive Hydration Serum                | Drunk Elephant   |
| P429582    | 3.8932         | 487           | Jet Lag Mask                                     | Summer Fridays   |
| P309308    | 4.2304         | 447           | Good Genes All-In-One Lactic Acid Treatment      | SUNDAY RILEY     |
| P426836    | 4.0858         | 443           | Beste No. 9 Jelly Cleanser                       | Drunk Elephant   |
| P418218    | 3.9887         | 441           | The Water Cream                                  | Tatcha           |
| P415777    | 4.3622         | 439           | T.L.C. Sukari Babyfacial AHA + BHA Mask          | Drunk Elephant   |
| P236816    | 4.3442         | 430           | Dior Lip Glow                                    | Dior             |

Rajah Error! No text of specified style in document..6 Paparan antara muka untuk mendapatkan cadangan produk kosmetik popular.



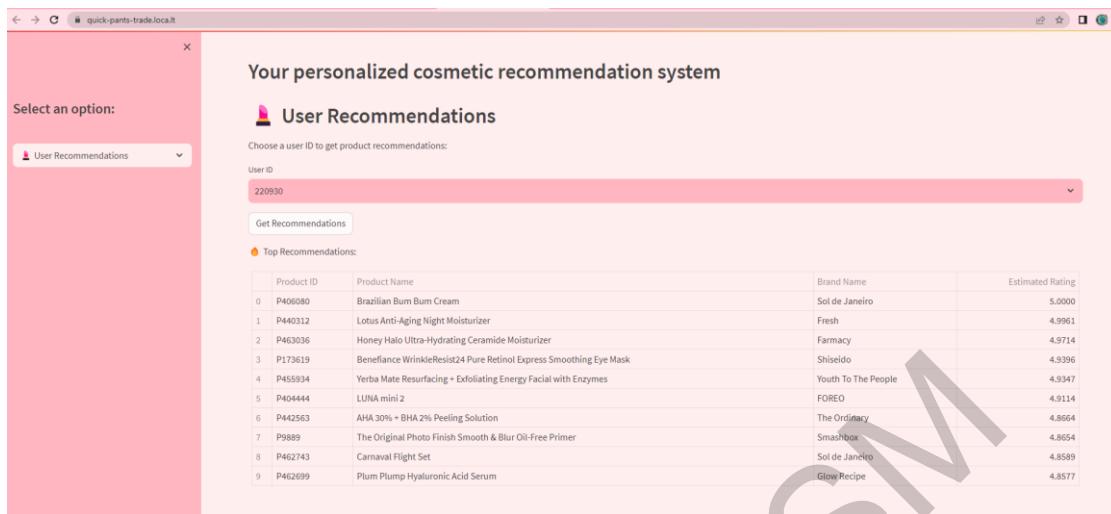
The screenshot shows a table titled "Weighted Popularity" listing various cosmetic products along with their ratings, rating counts, and scores. The products include items like Plum Plump Hyaluronic Acid Serum, Honey Halo Ultra-Hydrating Ceramide Moisturizer, and LUNA mini 2.

|  | rating | rating_counts | score  |
|--|--------|---------------|--------|
| Plum Plump Hyaluronic Acid Serum                                   | 4.8485 | 33            | 4.7640 |
| Honey Halo Ultra-Hydrating Ceramide Moisturizer                    | 4.8049 | 41            | 4.7398 |
| Benefiance Wrinkle Smoothing Day Cream SPF 23                      | 4.9167 | 12            | 4.7077 |
| Vitamin Enriched Eye Base  | 4.8333 | 18            | 4.6970 |
| AHA 30% + BHA 2% Peeling Solution                                  | 4.7052 | 268           | 4.6961 |
| Yerba Mate Resurfacing + Exfoliating Energy Facial with Enzymes    | 4.7241 | 58            | 4.6830 |
| LUNA mini 2  | 4.6733 | 101           | 4.6512 |
| A-Passioni Retinol Cream Mini                                      | 5.0000 | 6             | 4.6392 |
| ShineOn Jelly Lip Gloss  | 4.6620 | 71            | 4.6320 |
| ExfoliKate Cleanser Daily Foaming Wash                             | 4.6500 | 100           | 4.6289 |
| Carnaval Flight Set  | 4.6897 | 29            | 4.6186 |
| Salicylic Acid Acne Treatment Serum                                | 4.6765 | 34            | 4.6162 |
| The Rice Wash Skin-Softening Cleanser                              | 4.6418 | 67            | 4.6115 |
| Dream Eye Cream with Goji Stem Cell and Ceramides                  | 4.7000 | 20            | 4.6013 |
| Aqua Bomb Deep Hydration Set                                       | 4.8571 | 7             | 4.5859 |
| Benefiance WrinkleResist24 Pure Retinol Express Smoothing Eye Mask | 4.6061 | 66            | 4.5779 |
| Alpha Beta Extra Strength Daily Peel                               | 4.5611 | 303           | 4.5553 |
| Transforming Walnut Scrub  | 4.5610 | 246           | 4.5539 |
| Limited Edition Lip Sleeping Mask                                  | 4.6471 | 17            | 4.5469 |
| Lotus Anti-Aging Night Moisturizer                                 | 4.5570 | 158           | 4.5462 |

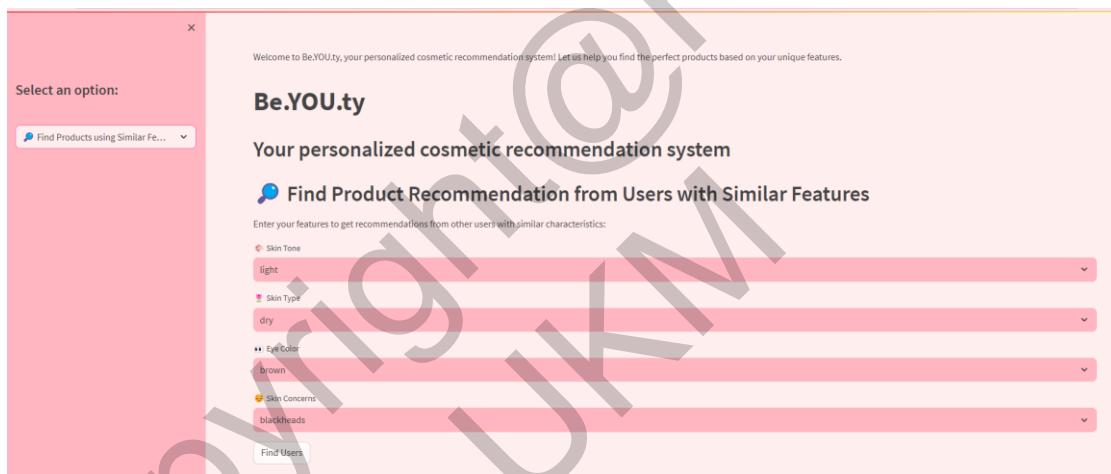
Rajah **Error! No text of specified style in document..7** Paparan antara muka untuk mendapatkan cadangan produk kosmetik dengan *weighted-rating*.



Rajah **Error! No text of specified style in document..8** Paparan antara muka untuk mendapatkan produk kosmetik berdasarkan kolaboratif.



Rajah Error! No text of specified style in document..9 Paparan antara muka untuk mendapatkan cadangan produk kosmetik berdasarkan ciri-ciri pengguna.



Rajah Error! No text of specified style in document..10 Output cadangan produk kosmetik berdasarkan ciri-ciri pengguna.

| rating | brand                | name   | user_id |
|--------|----------------------|--|---------|
| 4.2332 | 5 Kate Somerville    | ExfoliKate Cleanser Daily Foaming Wash         | 24171   |
| 2.9596 | 5 Kiehl's            | Midnight Recovery Concentrate                  | 20478   |
| 2.8436 | 5 SEPHORA COLLECTION | Cleansing & Exfoliating Wipes                  | 20478   |
| 2.6696 | 5 Bobbi Brown        | Vitamin Enriched Face Base Priming Moisturizer | 25391   |
| 2.5980 | 5 Biossance          | Squalane + Marine Algae Eye Cream              | 87403   |
| 3.2153 | 5 Dr. Jart+          | Ceramidin Cream                                | 156171  |
| 2.5051 | 5 Fresh              | Rose & Hyaluronic Acid Deep Hydration Toner    | 156171  |
| 9.05   | 5 Drunk Elephant     | Protnini Polypeptide Moisturizer               | 25391   |
| 2.1867 | 5 Tatcha             | The Rice Wash Skin-Softening Cleanser          | 82765   |
| 1.8580 | 5 Shiseido           | Benefiance Wrinkle Smoothing Eye Cream         | 87403   |

Rajah Error! No text of specified style in document..11 Output cadangan produk kosmetik berdasarkan ciri-ciri pengguna.

## Kesimpulan

Kesimpulannya, kajian ini telah mencapai kemajuan yang ketara ke arah pembangunan sistem pencadang produk kosmetik yang mantap dan diperibadikan. Dengan membandingkan dan menilai pelbagai algoritma pengesyoran, kajian ini telah berjaya menangani cabaran yang dihadapi oleh pengguna dalam perjalanan membeli-belah product kosmetik dalam talian mereka.

Sistem pencadang ini memanfaatkan teknik penapisan berdasarkan kandungan dan kolaboratif, bersama dengan ciri khusus pengguna, untuk memberikan cadangan produk yang tepat dan berkaitan. Penyertaan senarai produk populariti seterusnya membantu pengguna untuk terus mendapat maklumat tentang trend terkini dalam industri kosmetik. Walaupun menghadapi batasan dalam perkakasan dan perisian, penyelidikan ini dapat berfungsi sebagai titik permulaan untuk usaha masa depan dalam bidang sistem pencadang.

Akhirnya, objektif projek untuk memastikan pengguna dicadangkan dengan produk kosmetik yang selaras dengan cita-rasa dan keperluan mereka dapat dicapai. Dengan menggabungkan kuasa

algoritma sistem pencadang yang berlainan, kajian ini menyasarkan untuk mengubah cara pelanggan meneroka dan membeli produk kosmetik secara dalam talian

### **Penghargaan**

Pertama sekali saya ingin mengucapkan terima kasih kepada penyelia saya iaitu Dr. Lailatul Qadri Binti Zakaria kerana sudi memberikan tunjuk ajar, bimbingan dan nasihat kepada saya sewaktu melaksanakan tugas projek akhir ini. Pengertian, dorongan dan sokongan yang diberikan oleh beliau sepanjang tempoh memenuhi tugas ini amat dihargai.

Saya juga ingin mengambil kesempatan ini untuk menunjukkan penghargaan saya kepada ahli keluarga dan kawan-kawan saya kerana sentiasa memberi dorongan dan kata-kata semangat sewaktu melaksanakan projek ini.

Akhir sekali, saya juga sangat bersyukur kepada Tuhan kerana mengurniakan saya dengan kecekalan untuk menghadapi segala cabaran dan dugaan yang saya alami sepanjang tempoh menyiapkan projek akhir ini dalam jangka masa yang ditetapkan.

### **RUJUKAN**

Adelola Adebo. 2020. A Natural Language Processing Approach to a Skincare Recommendation Engine. Dublin: National College of Ireland.

Adinarayana Salina, Yugeswara Rao Yogi Rao, K. & Murthy, G.S.N. 2017. Product Recommendation System from Users Reviews using Sentiment Analysis. Visakhapatnam: Gandhi Institute of Technology and Management.

al Fararni, Khalid, Aghoutane, Badraddine, Yahyaouy, Ali, Riffi, Jamal & Abdelouahed, Sabri. 2021. Tourism recommender systems: an overview. International Journal of Cloud Computing. 10. 603. 10.1504/IJCC.2021.120397.

Ashwini Lokesh. 2019. A Comparative Study of Recommendation Systems. Tesis Dr. Wang, Western Kentucky University.

- Dwivedi, R. 2020. What are recommendation systems in machine learning? Analytics Steps. <https://www.analyticssteps.com/blogs/what-are-recommendation-systems-machine-learning> [15 November 2022].
- Gediminas Adomavicius & Alexander Tuzhilin. 2005. Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. Minneapolis: University of Minnesota.
- Ji, Yitong, Aixin Sun, Jie Zhang, & Chenliang Li. "A critical study on data leakage in recommender system offline evaluation." *ACM Transactions on Information Systems* 41(3): 1-27.
- Ji, Yitong, Aixin Sun, Jie Zhang, & Chenliang Li. 2020. "A re-visit of the popularity baseline in recommender systems." In Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval: 1749-1752.
- Kementerian Kesihatan Malaysia. (KKM) 2019. Beauty products or cosmetics? <http://www.myhealth.gov.my/produk-kecantikan-atau-produk-kosmetik/> [13 November 2022].
- Keshetti Sreekala. 2020. Popularity Based Recommendation System. . *Journal of Engineering and Advanced Technology (IJEAT)* 9(3). ISSN: 2249-8958.
- Kuanr, Madhusree & Puspanjali Mohapatra. 2021. "Assessment Methods for Evaluation of Recommender Systems: A Survey." *Foundations of Computing and Decision Sciences* 46: 393 - 421.
- Li Chen, Guanliang Chen & Feng Wang. 2015. Recommender systems based on user reviews: the state of the art. Hong Kong: Hong Kong Baptist University
- Mikolov, Tomas, Kai Chen, Greg Corrado & Jeffrey Dean. 2013. "Efficient estimation of word representations in vector space." arXiv preprint arXiv:1301.3781
- Nageswara Rao, K., & Talwar, V.G. 2008. Application Domain and Functional Classification of Recommender Systems – A survey. DESIDOC. *Journal of Library & Information Technology* 28(3): 17-35. <https://publications.muet.edu.pk/index.php/muetrij/article/view/555> [10 Januari 2023].
- S. Roy, M. Sharma & S. K. Singh. 2019. "Movie Recommendation System Using Semi-Supervised Learning," 2019 Global Conference for Advancement in Technology (GCAT), Bangalore, India: 1-5, doi: 10.1109/GCAT47503.2019.8978353.
- Stomberg, Joshua C. 2014. A Comparative Study and Evaluation of Collaborative Recommendation Systems. Tesis Dr. Brown, Michigan Technological University.
- Subodh Gholve. 2020. Research Paper Recommendation System. Tesis. Cardiff University.
- Sura I. Mohammed Ali & Sadiq Sahip Majeed. 2021. A Review of collaborative filtering Recommendation System. *Muthanna Journal of Pure Science* 8(1). [https://www.researchgate.net/publication/351528876\\_A\\_Review\\_of\\_collaborative\\_filtering\\_Recommendation\\_System](https://www.researchgate.net/publication/351528876_A_Review_of_collaborative_filtering_Recommendation_System) [10 Januari 2023].

Umair Shafique & Haseeb Qaiser. 2014. A Comparative Study of Data Mining Process Models (KDD, CRISP-DM and SEMMA). International Journal of Innovation and Scientific Research 12: 2351-8014.

Villia Putriany, Jaidan Jauhari & Rahmat Izwan Heroza. 2019. Item Clustering as An Input for Skin Care Product Recommended System Using Content Based Filtering. Indralaya: Sriwijaya University.

Yitong Ji, Aixin Sun, Jie Zhang, and Chenliang Li. 2023. A Critical Study on Data Leakage in Recommender System Offline Evaluation. ACM Trans. Inf. Syst. 41(3): 1-27.  
<https://doi.org/10.1145/3569930>

Arvind Naido A/L Thirumoorthy (A181506)

Dr. Lailatul Qadri Binti Zakaria

Fakulti Teknologi & Sains Maklumat,

Universiti Kebangsaan Malaysia