

Implementasi Teori Graf dan Operasi Himpunan Saling Lepas untuk Deteksi Komunitas Terisolasi pada Algoritma FYP TikTok

Mochammad Nuha Al Ghifari - 13525056

Program Studi Teknik Informatika

Sekolah Teknik Elektro dan Informatika

Institut Teknologi Bandung, Jalan Ganesha 10 Bandung

E-mail: nuhaa.alghifari@gmail.com , 13525056@std.stei.itb.ac.id

Abstrak—Algoritma For You Page (FYP) TikTok mempersonalisasi konten sehingga pengguna berminat serupa cenderung saling tersodori konten yang sama. Bila personalisasi terlalu kuat, jaringan pengguna dapat terpecah menjadi kelompok terisolasi yang hanya berinteraksi dengan kalangan sendiri, yaitu echo chamber. Makalah ini memodelkan pola eksposur tersebut sebagai graf tak-berarah dan menunjukkan bahwa pendeteksian echo chamber setara dengan pencarian komponen terhubung, yang secara teori himpunan merupakan partisi simpul menjadi kelas-kelas ekuivalensi yang saling lepas (disjoint). Partisi tersebut dihitung dengan struktur data Himpunan Saling Lepas (Disjoint Set Union/Union-Find) memakai penyatuan menurut peringkat dan pemampatan lintasan. Karena data FYP TikTok tidak terbuka, evaluasi memakai jaringan ko-eksposur sintesis Stochastic Block Model dengan enam kelompok minat. Penyapuan intensitas eksposur lintas-minat memperlihatkan transisi perkolasi yang tajam: di bawah ambang kritis seluruh pengguna menyatu pada satu komponen raksasa, sedangkan di atasnya jaringan pecah menjadi enam komunitas terisolasi dengan kemurnian 1,000 terhadap kelompok minat laten. Union-Find teroptimasi memproses 64.000 simpul lebih dari 300 kali lebih cepat daripada pencarian naif, menegaskan kelayakannya pada jaringan besar.

Kata kunci—komponen terhubung; echo chamber; graf; himpunan saling lepas; relasi ekuivalensi; Union-Find

I. PENDAHULUAN

TikTok menjadi salah satu aplikasi paling banyak digunakan berkat laman rekomendasi For You Page (FYP). Berbeda dengan media sosial yang menampilkan unggahan teman, FYP menyodorkan konten berdasarkan tebakan minat pengguna dari riwayat tontonan, lama menonton, suka, dan bagikan [13]. Personalisasi yang sangat agresif inilah yang membuat FYP terasa “mengerti” penggunaannya, tetapi sekaligus menimbulkan kekhawatiran: bila setiap orang hanya dipertemukan dengan konten dan, secara tidak langsung, dengan orang-orang yang sudah sepaham, terbentuklah ruang gema atau echo chamber, yaitu lingkungan tempat keyakinan diperkuat oleh pengulangan di dalam kelompok tertutup [9], [10].

Secara intuitif, echo chamber adalah sekelompok pengguna yang sangat rapat di dalam tetapi nyaris tidak tersambung ke luar. Gambaran “rapat di dalam, terputus ke luar” ini sebenarnya adalah konsep yang sudah baku dalam Matematika

Diskrit, yaitu komponen terhubung pada sebuah graf. Bila pengguna dimodelkan sebagai simpul dan kesamaan eksposur konten sebagai sisi, maka mendeteksi echo chamber berubah menjadi persoalan memartisi simpul ke dalam komponen-komponen terhubungnya.

Yang menjadikan persoalan ini menarik dari sudut Matematika Diskrit adalah keterkaitannya yang rapi antara tiga pokok bahasan. Pertama, relasi “dapat saling dijangkau” pada graf merupakan relasi ekuivalensi. Kedua, setiap relasi ekuivalensi memartisi himpunan menjadi kelas-kelas yang saling lepas (disjoint). Ketiga, partisi tersebut dapat dipelihara secara efisien oleh struktur data Himpunan Saling Lepas (Disjoint Set Union, kerap disebut Union-Find). Dengan demikian, judul makalah ini bukan sekadar penggabungan istilah: teori graf menyediakan model, teori himpunan menjelaskan maknanya, dan operasi pada himpunan saling lepas memberi algoritmanya.

Perlu ditegaskan sejak awal bahwa data jaringan FYP TikTok yang sebenarnya tidak tersedia untuk umum. Maka makalah ini tidak mengklaim menganalisis data TikTok asli, melainkan membangun jaringan ko-eksposur sintesis yang perilakunya menyerupai FYP memakai Stochastic Block Model [6], lalu menerapkan deteksi komunitas di atasnya. Tujuannya bersifat ilustratif dan reproducible: memperlihatkan bagaimana konsep diskrit bekerja dan kapan echo chamber muncul, bukan mengukur TikTok secara empiris.

Kontribusi makalah ini ada empat. Pertama, merumuskan deteksi echo chamber sebagai pencarian komponen terhubung dan menautkannya secara formal dengan relasi ekuivalensi serta partisi himpunan saling lepas. Kedua, mengimplementasikan Union-Find lengkap dengan penyatuan menurut peringkat dan pemampatan lintasan beserta analisis kompleksitasnya. Ketiga, menyajikan contoh perhitungan tangan yang dapat diperiksa langkah demi langkah. Keempat, menjalankan simulasi penyapuan kekuatan personalisasi yang menunjukkan adanya ambang kritis kemunculan echo chamber.

Sisa makalah disusun sebagai berikut. Bagian II meninjau pekerjaan terkait dan menegaskan posisi tulisan ini. Bagian III memaparkan landasan teori graf dan himpunan. Bagian IV memodelkan echo chamber dan menjabarkan algoritma Union-Find beserta contoh tangan. Bagian V merinci rancangan

simulasi, dan Bagian VI membahas hasilnya. Bagian VII menutup dengan kesimpulan.

II. PEKERJAAN TERKAIT DAN POSISI MAKALAH

Echo chamber dan filter bubble telah lama dibahas pada kajian media sosial. Sunstein [9] mengingatkan bahaya ruang gema bagi wacana publik, sedangkan Bakshy, Messing, dan Adamic [11] mengukur paparan berita beragam di Facebook dan menemukan peran penyaringan algoritmik maupun pilihan pengguna. Cinelli dkk. [10] membandingkan beberapa platform dan menunjukkan efek echo chamber yang nyata pada jejaring yang sangat dipersonalisasi. Klug dkk. [12] mempelajari asumsi pengguna tentang algoritma TikTok. Makalah-makalah tersebut bersifat empiris dengan data nyata berskala besar.

Dari sisi metode, pencarian komunitas pada graf merupakan bidang yang matang [7]. Banyak algoritma canggih, seperti modularitas dan pemetaan spektral [8], mampu menemukan komunitas yang tumpang tindih dan berhierarki. Makalah ini sengaja memilih alat yang paling sederhana, yaitu komponen terhubung melalui Union-Find, karena tiga alasan. Pertama, komponen terhubung memiliki makna himpunan yang tepat (kelas ekuivalensi) sehingga selaras dengan tujuan pembelajaran Matematika Diskrit. Kedua, algoritmanya dapat dihitung tangan dan diverifikasi. Ketiga, dengan menyaring sisi lemah lebih dahulu, komponen terhubung sudah cukup memisahkan kelompok yang benar-benar terisolasi, yang merupakan inti definisi echo chamber.

Dengan demikian, posisi makalah ini jujur dan terbatas: ia bukan studi empiris atas TikTok dan bukan pula metode deteksi komunitas baru. Nilainya terletak pada penerapan konsep Matematika Diskrit secara mandiri dan dapat ditelusuri pada persoalan yang relevan, lengkap dengan simulasi yang memperlihatkan kapan echo chamber terbentuk.

III. LANDASAN TEORI

A. Graf dan Komponen Terhubung

Sebuah graf tak-berarah $G = (V, E)$ terdiri atas himpunan simpul V dan himpunan sisi E yang setiap anggotanya adalah pasangan tak-terurut dua simpul [1], [2]. Sebuah lintasan dari u ke v adalah barisan simpul berurutan yang setiap pasangannya terhubung sisi. Dua simpul dikatakan saling terhubung bila terdapat lintasan di antara keduanya. Komponen terhubung adalah himpunan bagian simpul maksimal yang setiap pasangannya saling terhubung.

B. Relasi Ekuivalensi dan Partisi

Definisikan relasi $\sim$ pada V dengan $u \sim v$ bila u dan v saling terhubung (termasuk $u \sim u$). Relasi ini bersifat refleksif karena setiap simpul terhubung ke dirinya melalui lintasan kosong, simetris karena graf tak-berarah sehingga lintasan dapat dibalik, dan transitif karena lintasan $u-v$ dan $v-w$ dapat disambung menjadi lintasan $u-w$. Ketiga sifat ini menjadikan $\sim$ sebuah relasi ekuivalensi [1].

Teorema baku dalam teori himpunan menyatakan bahwa setiap relasi ekuivalensi pada V menghasilkan partisi V , yaitu sekumpulan kelas ekuivalensi yang tidak kosong, sepasang-sepasang saling lepas, dan gabungannya sama dengan V . Kelas ekuivalensi relasi $\sim$ tidak lain adalah komponen terhubung graf. Secara ringkas, untuk partisi $P = \{C_1, C_2, \dots, C_k\}$ berlaku:

$$C_i \neq \emptyset; C_i \cap C_j = \emptyset \text{ untuk } i \neq j; C_1 \cup C_2 \cup \dots \cup C_k = V.$$

Inilah jembatan utama makalah: mendeteksi komunitas terisolasi sama dengan menghitung partisi simpul menjadi himpunan-himpunan saling lepas. Tiap echo chamber adalah satu kelas C_i .

C. Struktur Data Himpunan Saling Lepas

Himpunan Saling Lepas (Disjoint Set Union, DSU) atau Union-Find adalah struktur data yang memelihara partisi sebuah himpunan ke dalam blok-blok saling lepas dan menyediakan dua operasi pokok [3], [4]: Find(x) yang mengembalikan wakil (akar) blok pemilik x , dan Union(x, y) yang menggabungkan dua blok menjadi satu. Setiap blok disimpan sebagai pohon berakar; akar menjadi wakil bloknya. Dua simpul berada pada satu blok bila dan hanya bila Find keduanya menghasilkan akar yang sama, sehingga uji keanggotaan partisi menjadi sangat mudah.

Dua pengoptimalan baku membuat operasi nyaris berbiaya tetap. Penyatuan menurut peringkat (union by rank) selalu menggantungkan pohon yang lebih pendek di bawah yang lebih tinggi sehingga pohon tetap dangkal. Pemampatan lintasan (path compression) menautkan langsung setiap simpul yang dilewati Find ke akar. Dengan keduanya, Tarjan [5] membuktikan bahwa m operasi pada n elemen berbiaya $O(m \cdot \alpha(n))$, dengan α fungsi balikan Ackermann yang nilainya tidak melampaui 4 untuk seluruh n praktis, sehingga praktis linear.

D. Penyaringan Ambang sebagai Filtrasi

Mendeteksi kelompok terisolasi pada graf berbobot lazim dilakukan dengan menyaring sisi lemah lebih dahulu lalu mengambil komponen terhubung; prosedur ini setara dengan pengelompokan pautan-tunggal (single linkage). Bila ambang t dinaikkan bertahap, himpunan sisi yang lolos menyusut secara monoton sehingga partisi yang dihasilkan kian halus: dua komponen tidak pernah bergabung kembali, melainkan hanya dapat terbelah. Rangkaian partisi bersarang ini disebut filtrasi, dan tiap tingkatnya cukup dihitung dengan satu jalan Union-Find. Sifat “hanya membelah” itu pula yang membuat Union-Find ideal: ia dirancang untuk menggabungkan, sehingga setiap nilai ambang diproses dari awal secara murah.

IV. PEMODELAN ECHO CHAMBER DAN METODE DETEKSI

A. Graf Ko-eksposur FYP

FYP tidak menyimpan hubungan pertemanan eksplisit, melainkan memutuskan konten apa yang ditampilkan kepada siapa. Dua pengguna disebut ber-ko-eksposur bila FYP berulang kali menyodorkan konten serupa kepada keduanya; intuisinya, mereka memiliki minat yang sama di mata algoritma. Pemodelan: bentuk graf tak-berarah berbobot $G = (V, E, w)$ dengan V himpunan pengguna, sisi $\{u, v\}$ ada bila keduanya pernah ber-ko-eksposur, dan bobot $w(u, v)$ mencatat berapa kali hal itu terjadi. Bobot besar menandakan kedekatan minat yang kuat.

Personalisasi dimodelkan sebagai ambang bobot t : hanya sisi dengan $w(u, v) \geq t$ yang dianggap mengikat dua pengguna ke dalam kelompok eksposur yang sama. Ambang yang tinggi mencerminkan FYP yang sangat selektif, yang hanya menautkan pengguna berkesamaan minat sangat tinggi. Atas graf terambang inilah komponen terhubung dicari; tiap

komponen besar yang terpisah dari sisanya adalah kandidat echo chamber.

B. Algoritma Deteksi

Prosedur deteksi diringkas pada Algoritma 1. Mula-mula setiap pengguna menjadi blok tersendiri. Untuk setiap sisi yang lolos ambang, kedua ujungnya disatukan. Setelah semua sisi diproses, pengguna dengan akar yang sama membentuk satu komponen, dan komponen berukuran di atas ambang tertentu dilaporkan sebagai echo chamber.

Algoritma 1. Deteksi echo chamber via Union-Find.

MASUKAN : graf berbobot $G=(V,E,w)$, ambang t ,
ukuran minimum s
KELUARAN: partisi V dan daftar echo chamber

```

1  buat DSU dengan  $|V|$  blok tunggal
2  untuk setiap sisi  $\{u,v\}$  dengan  $w(u,v) \geq t$ :
3      Union( $u, v$ )
4  kelompokkan  $v$  menurut Find( $v$ ) // partisi
5  laporkan komponen berukuran  $\geq s$ 

```

Operasi Find dan Union ditulis dengan kedua pengoptimalan:

Algoritma 2. Find dan Union teroptimasi.

```

fungsi Find( $x$ ):
    akar <-  $x$ 
    selama parent[akar] != akar:
        akar <- parent[akar]
    selama parent[ $x$ ] != akar: // kompresi
        parent[ $x$ ],  $x$  <- akar, parent[ $x$ ]
    kembalikan akar

fungsi Union( $a, b$ ):
    ra, rb <- Find( $a$ ), Find( $b$ )
    jika ra == rb: kembalikan
    jika rank[ra] < rank[rb]: tukar ra, rb
    parent[rb] <- ra // by rank
    jika rank[ra] == rank[rb]: rank[ra] += 1

```

C. Contoh Perhitungan Tangan

Untuk memperlihatkan peran ambang, tinjau delapan pengguna dengan sebagian bobot ko-eksposur pada Tabel I. Dengan ambang $t = 3$, hanya pasangan berbobot ≥ 3 yang dipertahankan, sehingga sisi lemah seperti $\{2,3\}$ (bobot 1) dan $\{5,6\}$ (bobot 2) yang menjembatani kelompok-kelompok justru tersingkir. Sisi yang tersisa persis yang tergambar pada Gambar 1.

Tabel I. Bobot ko-eksposur contoh dan penyaringan ambang.

Pasangan	Bobot w	Lolos $t=3$?
$\{0,1\}$	5	ya
$\{1,2\}$	4	ya
$\{0,2\}$	3	ya
$\{2,3\}$	1	tidak
$\{3,4\}$	6	ya
$\{4,5\}$	3	ya
$\{3,5\}$	4	ya
$\{5,6\}$	2	tidak
$\{6,7\}$	5	ya




Fig. 1. Gambar 1. Graf ko-eksposur contoh dengan delapan pengguna setelah penyaringan ambang.

Tinjau graf pada Gambar 1 dengan $V = \{0, 1, \dots, 7\}$ dan sisi terambang $\{0,1\}, \{1,2\}, \{0,2\}, \{3,4\}, \{4,5\}, \{3,5\}, \{6,7\}$ yang diproses berurutan. Jejak operasi Union (dengan banyak blok di kanan) adalah:

$Union(0,1) \rightarrow 6$; $Union(1,2) \rightarrow 5$; $Union(0,2)$ sudah sama;
 $Union(3,4) \rightarrow 4$; $Union(4,5) \rightarrow 3$; $Union(3,5)$ sudah sama;
 $Union(6,7) \rightarrow 2$.

$Union(0,2)$ dan $Union(3,5)$ tidak mengubah apa pun karena Find kedua ujungnya sudah menghasilkan akar yang sama, persis perilaku yang menghemat kerja. Hasil akhirnya adalah partisi

$$P = \{ \{0,1,2\}, \{3,4,5\}, \{6,7\} \},$$

yang memenuhi ketiga sifat partisi: tidak ada blok kosong, ketiganya saling lepas, dan gabungannya tepat V . Ketiga blok inilah ketiga komunitas terisolasi pada contoh, dan seluruhnya identik dengan keluaran program sehingga implementasi terverifikasi pada kasus yang dapat dihitung tangan.

V. RANCANGAN SIMULASI

A. Pembangkitan Jaringan Sintetis

Karena ketiadaan data FYP nyata, jaringan ko-eksposur dibangkitkan dengan Stochastic Block Model (SBM) berbobot [6]. Sebanyak $n = 1.200$ pengguna dibagi rata ke $c = 6$ kelompok minat laten, masing-masing 200 pengguna. Untuk tiap pasang pengguna, banyak ko-eksposur w dibangkitkan dari sebaran Poisson: dengan laju $\lambda_{dalam} = 4,0$ bila keduanya sekelompok dan λ_{luar} (kecil) bila berbeda kelompok. Sisi dipertahankan bila $w \geq 1$. Parameter λ_{luar} mengatur seberapa sering FYP mempertemukan minat berbeda; nilai kecil berarti personalisasi kuat.

Pemilihan SBM dapat dipertanggungjawabkan: ia adalah model baku untuk jaringan berstruktur kelompok dan memungkinkan kelompok minat laten diketahui pasti, sehingga komunitas hasil deteksi dapat dinilai kebenarannya. Tabel II merangkum parameter simulasi.

Tabel II. Parameter simulasi.

Parameter	Nilai
Banyak pengguna n	1.200
Banyak kelompok minat c	6 (@200)
Laju ko-eksposur sekelompok λ_{dalam}	4,0
Laju lintas-minat λ_{luar}	0,000–0,070
Ambang bobot t	3
Ukuran minimum echo chamber s	50

Benih acak	tetap (reproducible)
------------	----------------------

B. Ukuran Evaluasi

Tiga ukuran dilaporkan. Fraksi komponen raksasa, yaitu rasio ukuran komponen terbesar terhadap n , mendekati 1 bila jaringan menyatu dan mengecil bila pecah. Banyak echo chamber, yakni cacah komponen berukuran $\geq s = 50$. Kemurnian, yaitu rata-rata proporsi anggota komponen yang berasal dari satu kelompok minat laten; nilai 1,0 berarti komponen yang terdeteksi benar-benar sepadan dengan kelompok minat, sehingga layak disebut echo chamber.

C. Kompleksitas dan Lingkungan

Membangun DSU berbiaya $O(n)$, memproses seluruh sisi berbiaya $O(|E| \cdot \alpha(n))$, dan pengelompokan akhir $O(n \cdot \alpha(n))$; totalnya praktis linear terhadap ukuran graf. Seluruh program ditulis dalam Python tanpa pustaka graf khusus, dengan benih acak tetap sehingga setiap angka dan gambar pada makalah ini dapat dihasilkan ulang persis.

VI. HASIL DAN PEMBAHASAN

A. Transisi Kemunculan Echo Chamber

Gambar 2 menampilkan hasil penyapuan intensitas eksposur lintas-minat λ_{luar} pada ambang $t = 3$, dirata-rata atas lima benih acak. Terlihat transisi perkolasi yang tajam. Ketika $\lambda_{\text{luar}} \leq 0,012$, fraksi komponen raksasa hanya 0,167, artinya tidak ada komponen yang mendominasi dan jaringan terpecah menjadi enam komunitas berukuran sama. Saat λ_{luar} dinaikkan melewati sekitar 0,02, komunitas-komunitas mulai bergabung sehingga fraksi raksasa melonjak; pada $\lambda_{\text{luar}} = 0,070$ seluruh pengguna kembali menyatu pada satu komponen (fraksi 1,000).




Fig. 2. Gambar 2. Transisi perkolasi: fraksi komponen raksasa dan banyak echo chamber terhadap intensitas eksposur lintas-minat.

Maknanya gamblang: terdapat ambang kritis personalisasi. Selama FYP masih cukup sering menyelipkan konten lintas-minat, jaringan tetap menyatu dan echo chamber tidak terbentuk. Begitu eksposur lintas-minat ditekan di bawah ambang kritis, jaringan mendadak pecah menjadi kantong-kantong terisolasi. Temuan ini sejalan dengan teori perkolasi pada graf acak [8], [14] sekaligus memberi tafsir kebijakan yang sederhana: sedikit keberagaman eksposur sudah cukup mencegah fragmentasi.

Tabel III. Hasil penyapuan personalisasi (rata-rata 5 benih).

λ_{luar}	Fraksi raksasa # echo chamber	Kemurnian
-------------------------	-------------------------------	-----------

0,000	0,167	6,0	1,000
0,012	0,167	6,0	1,000
0,016	0,200	5,8	0,980
0,020	0,300	5,0	0,890
0,025	0,467	4,0	0,799
0,030	0,533	3,6	0,759
0,040	0,667	2,6	0,576
0,050	0,933	1,2	0,208
0,070	1,000	1,0	0,167

Posisi ambang kritis dapat dipahami melalui teori graf acak. Dua kelompok yang masing-masing sudah terhubung di dalam akan melebur begitu muncul setidaknya satu sisi lintas-minat yang lolos ambang di antara keduanya; banyak sisi semacam itu sebanding dengan λ_{luar} . Karena itu, kemunculan komponen raksasa menyerupai ambang perkolasi pada model Erdős–Rényi, tempat komponen raksasa lahir saat derajat rata-rata melewati satu [8], [14]. Ketajaman transisi pada Gambar 2 merupakan wujud fenomena ambang itu.

B. Kesahihan Komunitas Terdeteksi

Pada rezim personalisasi kuat ($\lambda_{\text{luar}} = 0,012$, $t = 3$), Union-Find menemukan tepat enam komponen, masing-masing beranggotakan 200 pengguna (Gambar 3), dengan kemurnian 1,000. Artinya setiap komunitas yang terdeteksi berisi persis satu kelompok minat laten tanpa pencampuran, sehingga benar-benar merupakan echo chamber dalam pengertian kelompok terisolasi yang seragam minat. Kemurnian menurun mulus seiring naiknya λ_{luar} , memperlihatkan peleburan bertahap antarkelompok sebelum akhirnya menyatu (Tabel III).





Fig. 3. Gambar 3. Ukuran komunitas pada rezim personalisasi kuat: enam echo chamber berukuran seragam.

C. Efisiensi Union-Find

Untuk menunjukkan kelayakan pada jaringan besar, Union-Find dioptimasi dibandingkan dengan pencarian akar naif tanpa peringkat maupun pemampatan lintasan, pada graf acak berukuran hingga 64.000 simpul dan 256.000 sisi (Gambar 4). Versi teroptimasi menyelesaikan kasus terbesar dalam 0,16 detik, lebih dari 300 kali lebih cepat daripada versi naif yang membutuhkan lebih dari 50 detik. Selisih ini melebar seiring ukuran, persis seperti yang diramalkan analisis kompleksitas praktis-linear pada Bagian III.



Gambar 4. Waktu Union-Find teroptimasi versus naif terhadap ukuran graf.

Tabel IV. Waktu eksekusi Union-Find ($m = 4n$ sisi).

n	Optimasi (s)	Naif (s)	Rasio
2.000	0,005	0,041	8,9×
8.000	0,018	0,567	30,9×
16.000	0,036	2,407	66,9×
32.000	0,074	10,74	144×
64.000	0,162	51,50	318×

D. Keterbatasan

Beberapa keterbatasan perlu dicatat secara jujur. Pertama, jaringan bersifat sintetis sehingga hasil bersifat ilustratif, bukan pengukuran TikTok yang sebenarnya; besaran ambang kritis bergantung pada parameter model. Kedua, komponen terhubung hanya menangkap echo chamber yang benar-benar terputus; ruang gema yang masih tersambung tipis ke luar memerlukan ukuran yang lebih halus seperti modularitas [7], [8]. Ketiga, model mengabaikan dimensi waktu dan arah pengaruh. Kesederhanaan ini disengaja agar seluruh metode dapat diturunkan, dihitung tangan, dan diverifikasi hanya dengan konsep graf dan himpunan.

VII. KESIMPULAN

Makalah ini menunjukkan bahwa deteksi komunitas terisolasi atau echo chamber pada jaringan ko-eksposur FYP dapat dirumuskan secara utuh memakai Matematika Diskrit. Echo chamber setara dengan komponen terhubung graf, yang secara teori himpunan merupakan kelas ekuivalensi dari relasi keterhubungan dan membentuk partisi simpul menjadi himpunan-himpunan saling lepas. Partisi tersebut dihitung efisien oleh struktur data Himpunan Saling Lepas dengan penyatuan menurut peringkat dan pemampatan lintasan, yang berbiaya praktis linear dan terbukti lebih dari 300 kali lebih cepat daripada pendekatan naif.

Simulasi pada jaringan Stochastic Block Model memperlihatkan adanya ambang kritis personalisasi: di bawah ambang seluruh pengguna menyatu, di atasnya jaringan pecah menjadi enam echo chamber murni yang sepadan dengan kelompok minat laten. Temuan ini menegaskan bahwa sedikit keberagaman eksposur lintas-minat sudah cukup mencegah fragmentasi. Pengembangan lanjutan dapat mengganti komponen terhubung dengan ukuran berbasis modularitas untuk menangkap echo chamber yang tersambung lemah, serta menguji model pada data interaksi nyata bila kelak tersedia.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen dan asisten mata kuliah IF1220 Matematika Diskrit atas penyampaian materi teori graf, relasi, dan himpunan yang menjadi landasan makalah ini.

KETERSEDIAAN KODE

Seluruh kode simulasi dan pembangkit gambar (`sim_echo.py`) memakai benih acak tetap sehingga setiap angka dan gambar pada makalah ini dapat dihasilkan ulang secara persis. Kode dapat disediakan sepenuhnya bersama berkas penyerahan makalah.

REFERENSI

- [1] K. H. Rosen, *Discrete Mathematics and Its Applications*, 8th ed. New York, NY, USA: McGraw-Hill, 2019.
- [2] R. Munir, *Matematika Diskrit*, 5th ed. Bandung, Indonesia: Penerbit Informatika, 2016.
- [3] T. H. Cormen, C. E. Leiserson, R. L. Rivest, and C. Stein, *Introduction to Algorithms*, 3rd ed. Cambridge, MA, USA: MIT Press, 2009, ch. 21.
- [4] B. A. Galler and M. J. Fischer, "An improved equivalence algorithm," *Communications of the ACM*, vol. 7, no. 5, pp. 301–303, 1964.
- [5] R. E. Tarjan, "Efficiency of a good but not linear set union algorithm," *Journal of the ACM*, vol. 22, no. 2, pp. 215–225, 1975.
- [6] P. W. Holland, K. B. Laskey, and S. Leinhardt, "Stochastic blockmodels: First steps," *Social Networks*, vol. 5, no. 2, pp. 109–137, 1983.
- [7] S. Fortunato, "Community detection in graphs," *Physics Reports*, vol. 486, no. 3–5, pp. 75–174, 2010.
- [8] M. E. J. Newman, *Networks*, 2nd ed. Oxford, UK: Oxford University Press, 2018.
- [9] C. R. Sunstein, *Republic.com 2.0*. Princeton, NJ, USA: Princeton University Press, 2007.
- [10] M. Cinelli, G. De Francisci Morales, A. Galeazzi, W. Quattrociocchi, and M. Starnini, "The echo chamber effect on social media," *Proceedings of the National Academy of Sciences*, vol. 118, no. 9, art. e2023301118, 2021.
- [11] E. Bakshy, S. Messing, and L. A. Adamic, "Exposure to ideologically diverse news and opinion on Facebook," *Science*, vol. 348, no. 6239, pp. 1130–1132, 2015.
- [12] D. Klug, Y. Qin, M. Evans, and G. Kaufman, "Trick and Please. A Mixed-Method Study On User Assumptions About the TikTok Algorithm," in *Proc. 13th ACM Web Science Conference (WebSci '21)*, 2021, pp. 84–92.
- [13] TikTok, "How TikTok recommends videos #ForYou," TikTok Newsroom, 2020. [Daring]. Tersedia: <https://newsroom.tiktok.com/en-us/how-tiktok-recommends-videos-for-you>, diakses 20 Juni 2026.
- [14] P. Erdős and A. Rényi, "On the evolution of random graphs," *Publ. Math. Inst. Hung. Acad. Sci.*, vol. 5, pp. 17–60, 1960.

PERNYATAAN

Dengan ini saya menyatakan bahwa makalah yang saya tulis ini adalah tulisan saya sendiri, bukan saduran, atau terjemahan dari makalah orang lain, dan bukan plagiasi.

Bandung, 19 Juni 2026

Mochammad Nuha Al Ghifari

13525056