

Music Recommendation

Denis Parra

IIC 3633 – Sistemas Recomendadores

10 de Noviembre de 2015

Agenda Semestral

27 - 29 Oct	Active/Reinforcement Learning Recommender Systems	Gabriel della Maggiora y Javier Machin
3 - 5 Nov	Graph-based recommendation	Juan Pablo Salazar y Christopher Arenas
10 - 12 Nov	Applications: music	Miguel Fadic
17 - 19 Nov	Modelos graficos probabilisticos para sistemas recomendadores	Laura Cruz (invitada)

Jueves 26 de Noviembre: Examen.

- 30 minutos de presentación para cada alumno (25 minutos + 5 de preguntas)
- Dura 4 horas, deben estar en todas las presentaciones de modo obligatorio

Escenario

- Grandes cambios en la forma en que se distribuye música en los últimos 20 años.
- En el pasado, una tienda tradicional poseía un catálogo de unos 10.000 items.
- En la actualidad, tiendas de música en línea o de streaming tienen catálogos del orden de un millón de artistas.
- Recomendadores en música: para encontrar, organizar y experimentar (consumir) música.

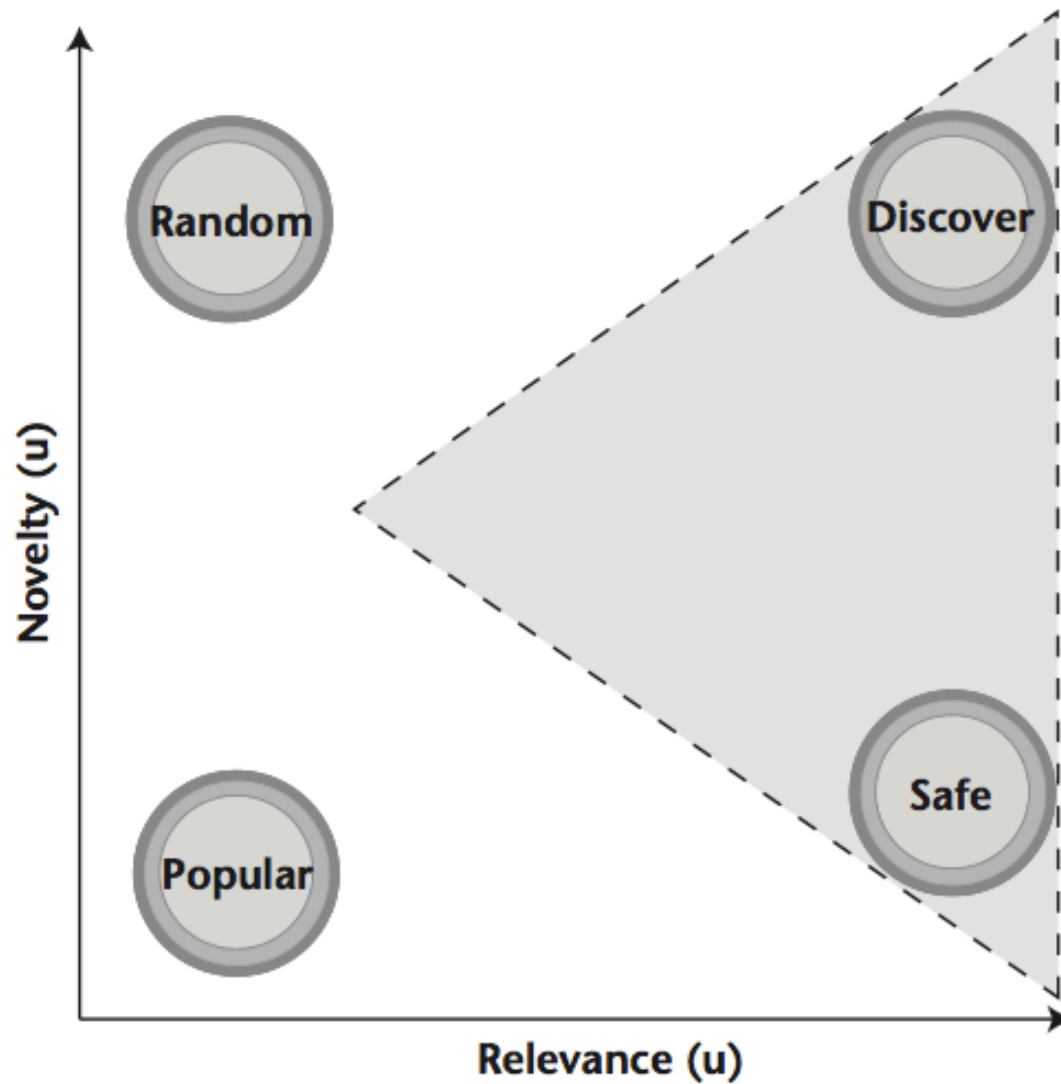
La industria musical

- Los DJs de radio han sido reemplazados por listas de canciones pre-programadas y el cajero de la tienda de música es rara vez un experto -> La gente espera que una máquina los guíe.
- Es importante incorporar entonces qué factores hacen a un buen sistema recomendador musical y cómo puede afectar el mundo de la música para construir sistemas que recomienden items novedosos, relevantes e interesantes.

En este survey:

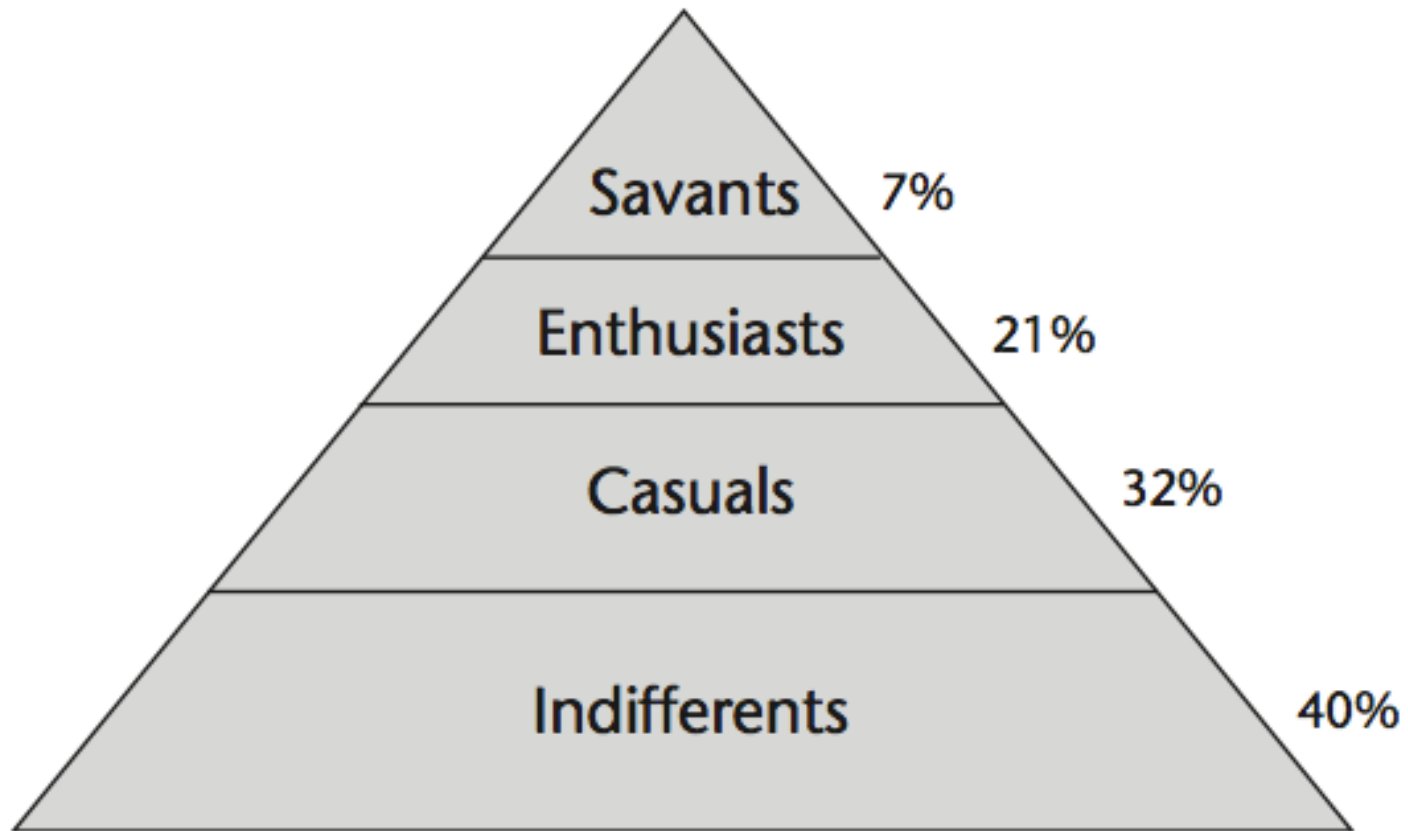
- Métodos estado del arte:
 - Usage based
 - Social based
 - Content based
 - Híbridos.

Balance entre Novedoso y Relevante



Estereotipos de Quienes Escuchan Música

- Proyecto inglés Phoenix 2 ~ (Jennings 2007)



... de las figuras anteriores

- Un recomendador musical efectivo debiese detectar qué tipo de consumidor musical es y en qué tipo de proceso está, por ejemplo, en descubrimiento o algo más relevante a lo ya escuchado

Casos de Uso

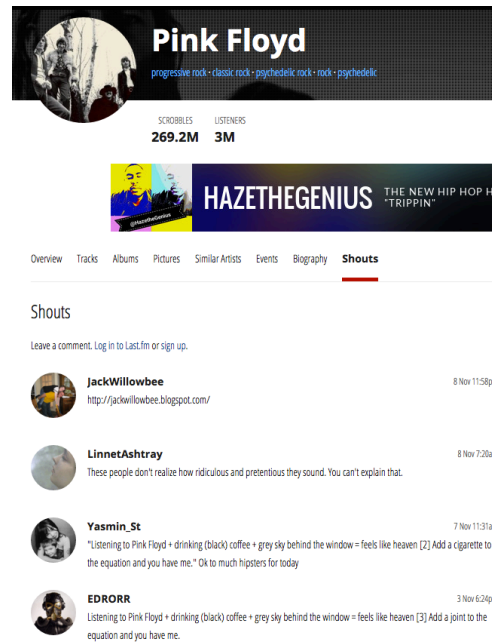
- Recomendación de Artista:
 - Bajo el clásico paradigma user-item

	Item 1	Item 2	...	Item m
User 1	1	5		4
User 2	5	1		?
...				
User n	2	5		?

- Tareas: planear una sesión para escuchar música, conocer nuevos artistas, conectar un fan con conciertos locales, re-descubrir música.

Casos de Uso II

- Recomendación de Usuarios
 - El objetivo es encontrar personas con gusto musical similar
 - Puede apoyar el descubrimiento de música nueva y relevante



The screenshot shows a Last.fm profile for Pink Floyd with 269.2M scrobbles and 3M listeners. Below the profile is a shoutbox for the track "HAZETHEGENIUS" by "THE NEW HIP HOP HIT 'TRIPPIN'". The shoutbox contains four comments from users JackWillowbee, LinnetAshtray, Yasmin_St, and EDRORR, all mentioning the song and their listening context.

Pink Floyd
progressive rock · classic rock · psychedelic rock · rock · psychedelic

SCROBBLES 269.2M LISTENERS 3M

HAZETHEGENIUS THE NEW HIP HOP HIT "TRIPPIN"

Overview Tracks Albums Pictures Similar Artists Events Biography **Shouts**

Shouts

Leave a comment. Log in to Last.fm or sign up.

JackWillowbee 8 Nov 11:58pm
<http://jackwillowbee.blogspot.com/>

LinnetAshtray 8 Nov 7:20am
These people don't realize how ridiculous and pretentious they sound. You can't explain that.

Yasmin_St 7 Nov 11:31am
"Listening to Pink Floyd + drinking (black) coffee + grey sky behind the window = feels like heaven [2] Add a cigarette to the equation and you have me." Ok to much hipsters for today

EDRORR 3 Nov 6:24pm
Listening to Pink Floyd + drinking (black) coffee + grey sky behind the window = feels like heaven [3] Add a pint to the equation and you have me.

Last.fm shoutbox

Playlist Generation

- Objetivo: construir una lista ordenada de canciones.
- Depende del contexto que el orden sea crítico o no: fiesta vs. trabajar, correr.
- “Shuffle” puede ser efectivo si el usuario está en proceso de discovery, pero a la vez es riesgoso cuando hay cambios extremos de estilo musical.
- Personalización: se adecúa al gusto del usuario y muchas veces provee feedback específico como “skip”, “ban”, “more like this”.

Métodos Básicos de Recomendación

- Usage-Based Recommender: Analisa los patrones de uso del usuario.
- El método más común está basado en filtrado colaborativo. Se contruye la matriz de interacción M_{UB} de dimensión $m \times n$.
- Uno de los primeros ejemplos de sistemas, Ringo (Shardanand, 1994) se basa en este modelo.
- Actualmente, estos modelos utilizand implicit feedback recommendation.

Métodos Básicos de Recomendación

- Social-Based Recommender: Utiliza contenido disponible en la Web.
 - Co-ocurrencia en páginas web (wikipedia o last.fm)
 - Canciones escuchada en el mismo log de sesión.
 - Uso de social tags -> genre, mood
 - CONS de CF y SB: cold-start, new item, influencia excesiva de items tempranos.

Métodos Básicos de Recomendación

- Content-Based Recommender: Deriva la similaridad directamente desde del audio.
- Trabajos iniciales en el área: extraer descriptores de timbre, como el Mel frequency cepstral coefficients.
 - Bag-of-frames: modelo de timbre bajo distribución en períodos cortos de tiempo.
 - A partir de BoF: GMM, KL divergence, EMD
- Otras features extraídas de forma automática: ritmo, tonalidad, acordes, género, mood.

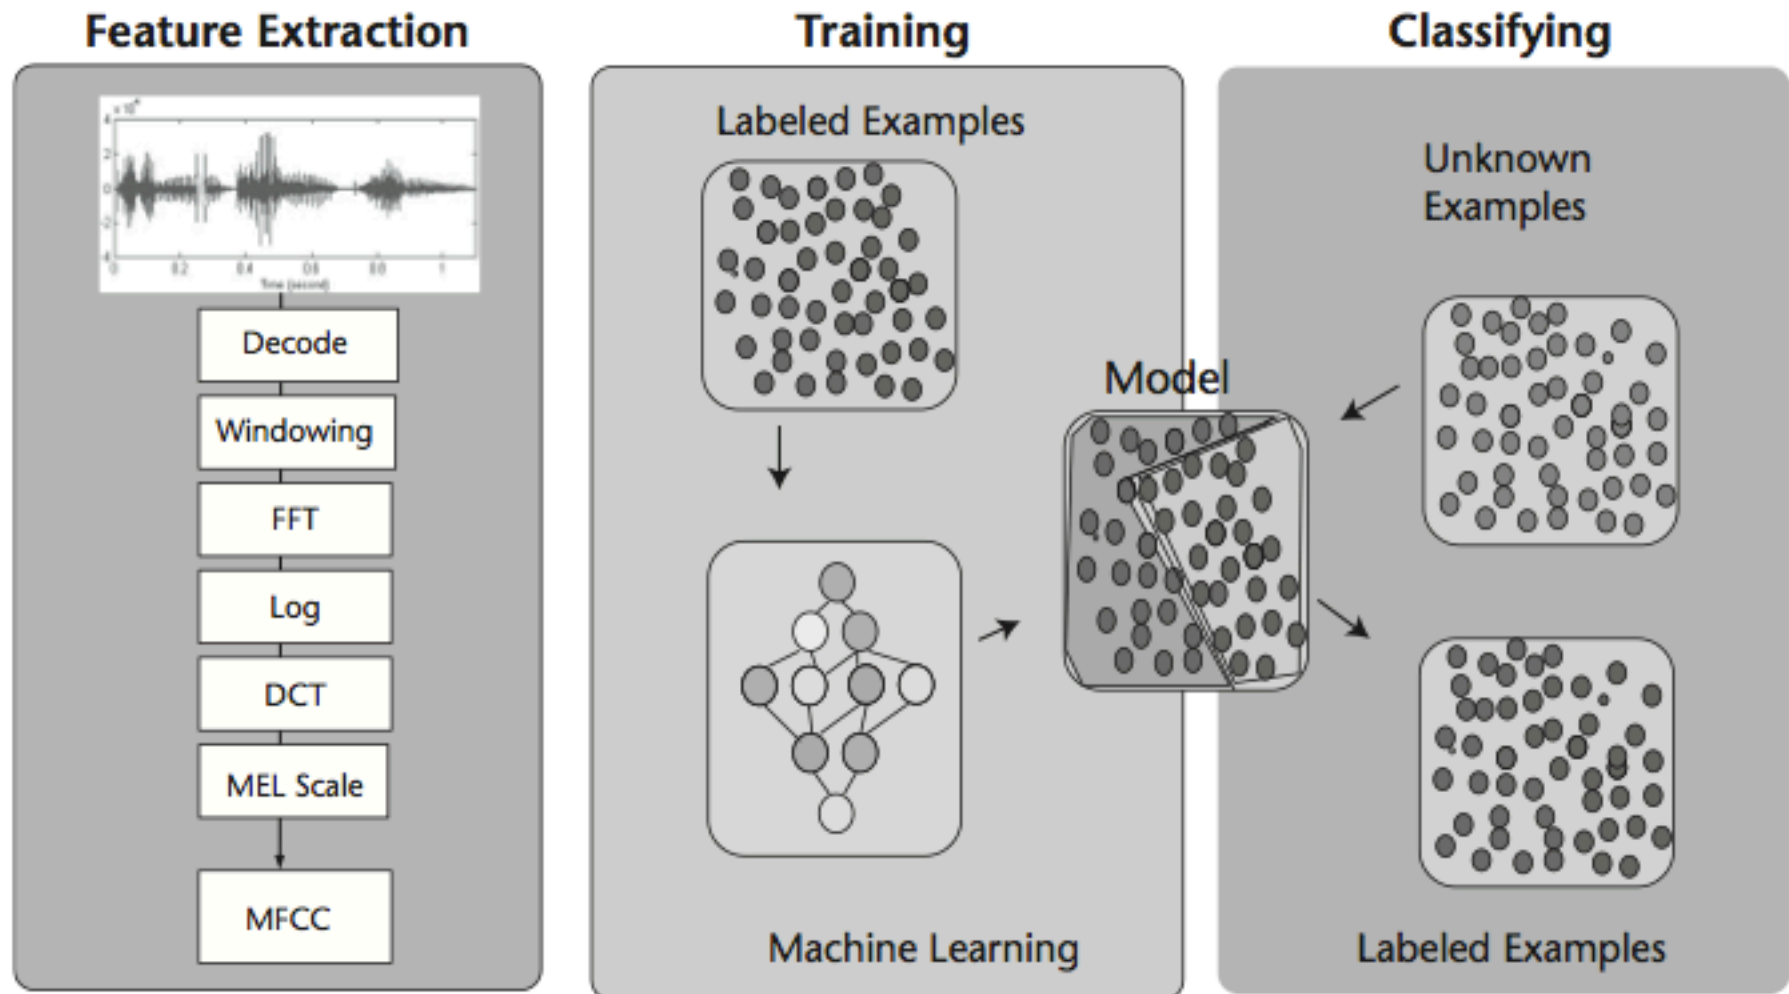
CB- methods

- Pueden encontrar piezas similares que pertenecen a distintos géneros musicales.
- Por ejemplo: una sonata de Franz Schubert y una balada de rock clásico “meat Loaf” contienen melodía de piano prominente.
- Son caros computacionalmente, por ejemplo, para aplicarlos a un dataset de millones de canciones.

Híbridos

- Métodos típicos son step-by-step o cascada.
- Por ejemplo, calcular similaridad usando item-based, luego re-ordenar en base a características sociales o acústicas.
- Combinación lineal de características.
- Otro método popular es usar una combinación CB y SB para predecir tags sociales (genre, mood) desde features de audio.

Modelo de Auto-etiquetado



Ejemplo Clásico: Celma thesis

- Oscar Celma recolectó un dataset de 360K usuarios desde last.fm, con 17M de datos de uso de 160K artistas en los años 2005-2008, datos de los top-n artistas ($n \leq 100$) más escuchados por cada usuario.
- También se recolectaron tags.
- Usando SVD se calculó similitudes entre artistas.

Ejemplo: Radiohead

Usage Based (UB)	Social Based (SB)	Content Based (CB)
Beck ₄₈₆₇	dEUS ₃₈₆₅	Autumn Defense ₅₀
dEUS ₃₈₆₅	Vita de Vie ₂₀₃	Anathema ₈₄₉₈
Kashmir ₁₅₀₂	Airship ₄	Augie March ₄₆₀
Doves ₃₇₈₇	B. Corgan & M. Garson ₇	Heather Duby ₁₉
Interpol ₂₀₅₆₈	Ostava ₁₉₈	The Standard ₃₄
Twilight Singers ₇₃₇	Galaxie 500 ₁₁₁₂	Jenny Owen Youngs ₄₃₅
Phoenix ₆₀₉₄	Enemy ₂₆₈ Maxímo Park ₇₅₆₂	Lavagance ₇₃
South ₄₁₄	State of Shock ₁₄₉	Jane Weaver ₁₀
Kings of Conv. ₁₁₀₂₀	This is serious mum! ₁₇₇	Sad Riders ₃
Magnet ₄₆₉		The Chrysler ₁₄

Table 1. Radiohead Top Ten Similar Artists Using the Three Recommendation Methods: Usage, Social, and Content Based.

Clustering of a User – Playlist Generation

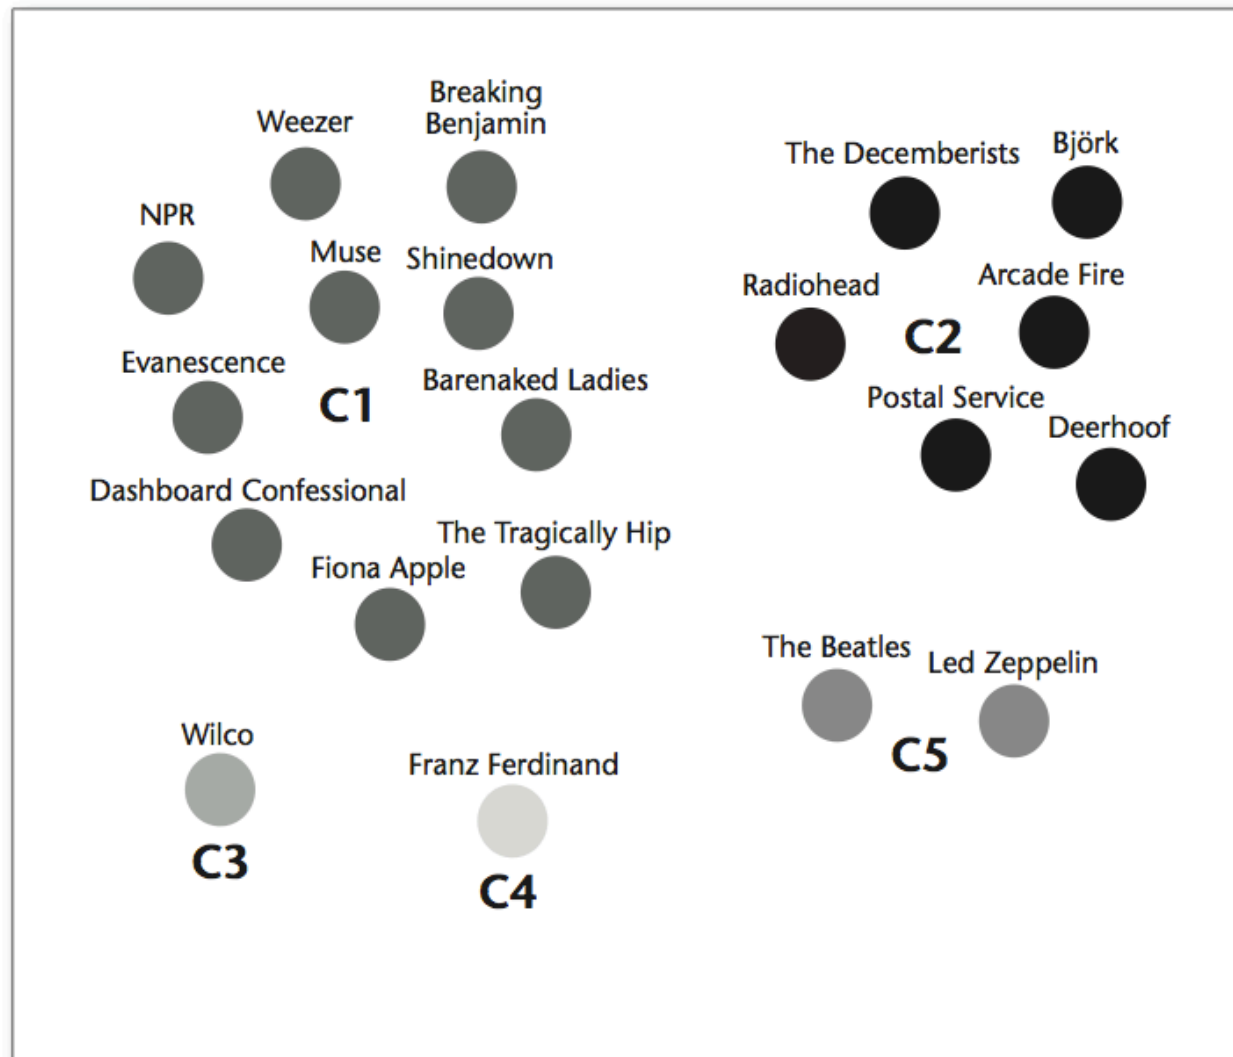


Figure 4. A User Profile Based on His or Her Top-20 Most Played Artists, Split on Five Clusters Using *k*-means Clustering. Similarity among the artists is derived from usage-based (CF) matrix M^{UB} . The closest cluster to Radiohead is C2.

Ejemplo: Recomendación Safe Versus Discovery

- <http://www.dtic.upf.edu/~ocelma/>

	Usage Based (UB)	Social Based (SB)	Content Based (CB)
Safe	Interpol ₂₀₅₆₈ Beck ₄₈₆₇ Doves ₃₁₇₈₇ Raconteurs ₆₀₃₈ P. Bjorn & John ₄₇₃₆	Daughtry ₂₅₃₆ dEUS ₃₈₆₅ Maximo Park ₇₅₆₂ British Sea Power ₁₇₈₃ Nada Surf ₅₀₉₇	Robag Wruhme ₁₂₉ Sono ₁₆₉ YACHT ₁₅₅ Märtini Brös ₁₂₆ Move D ₁₅₂
Discovery	Tiger Saw ₃ Morning Runner ₁₀₁ The Tacticians ₄ Naked Lunch ₁₁₅ Deportees ₁₅₈	Vespertines Airship ₄ State of Shock ₁₄₉ Dream City Film ₃₆ Raining Pleasure ₁₂₀	Fred Giannelli ₄ Stereomatic ₂₉ Freeform ₇₆ Sex In Dallas ₂₀ Heather DUBY ₁

Ejemplo: Moodplay

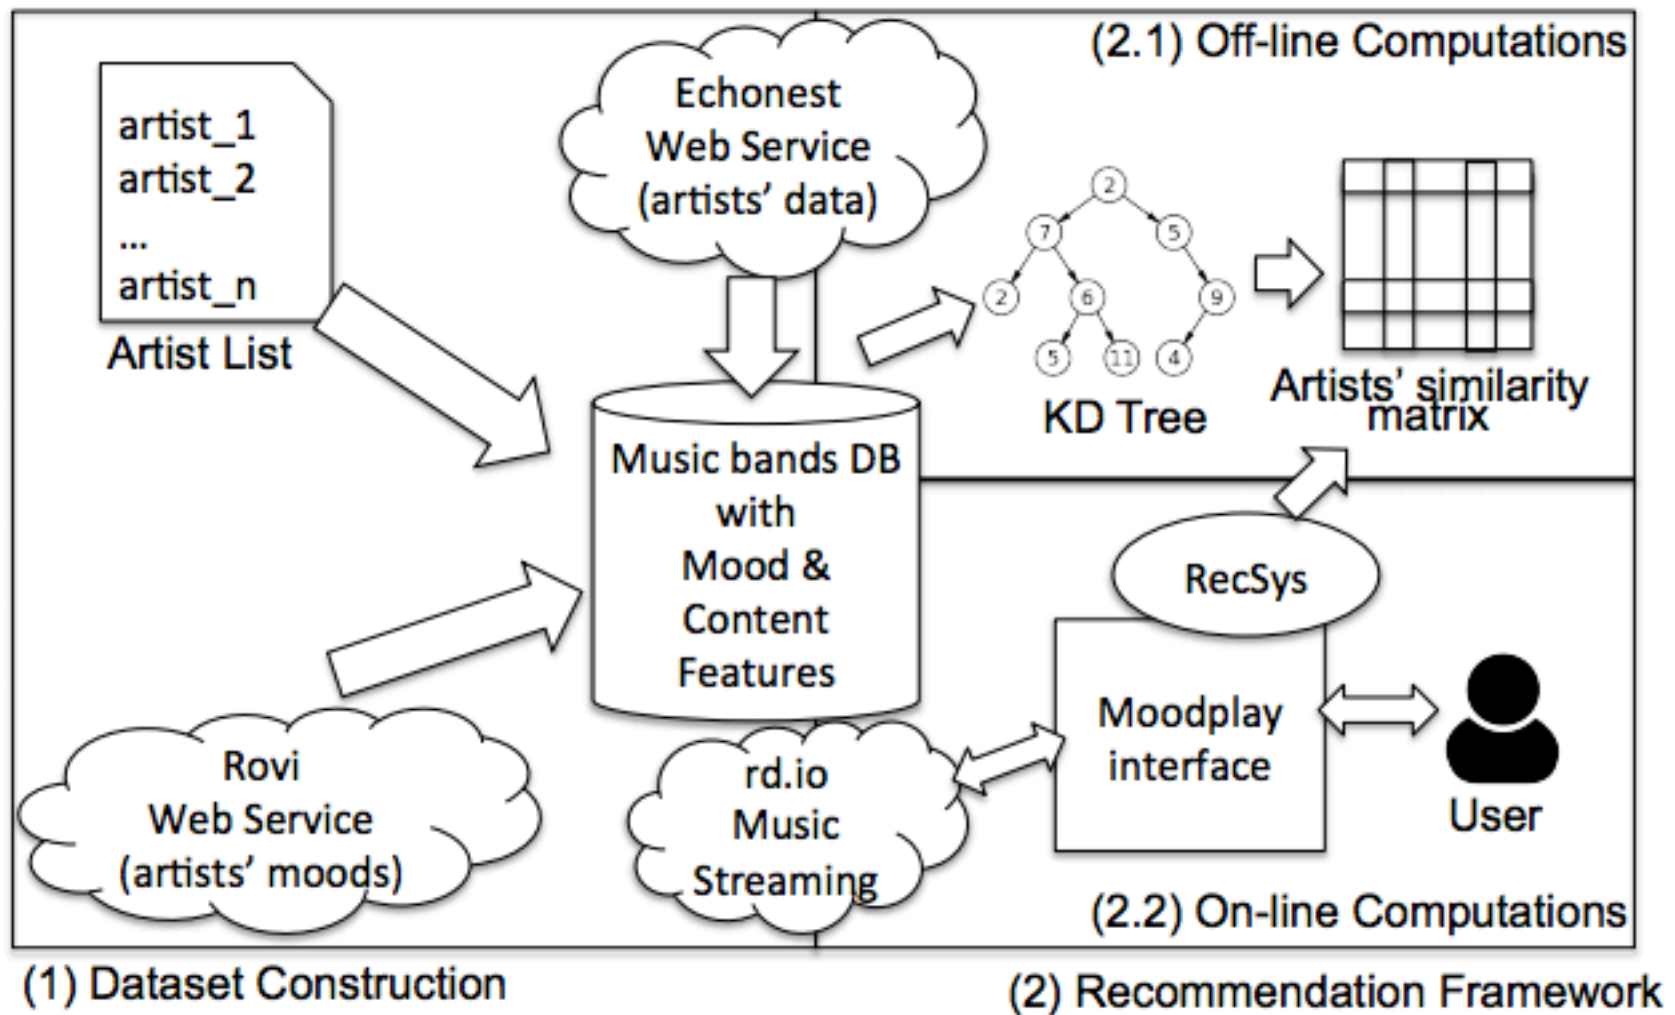
- MoodPlay
 - Ivana Andjelkovic (UCSB), Denis Parra (PUC Chile) & John O'Donovan (UCSB)



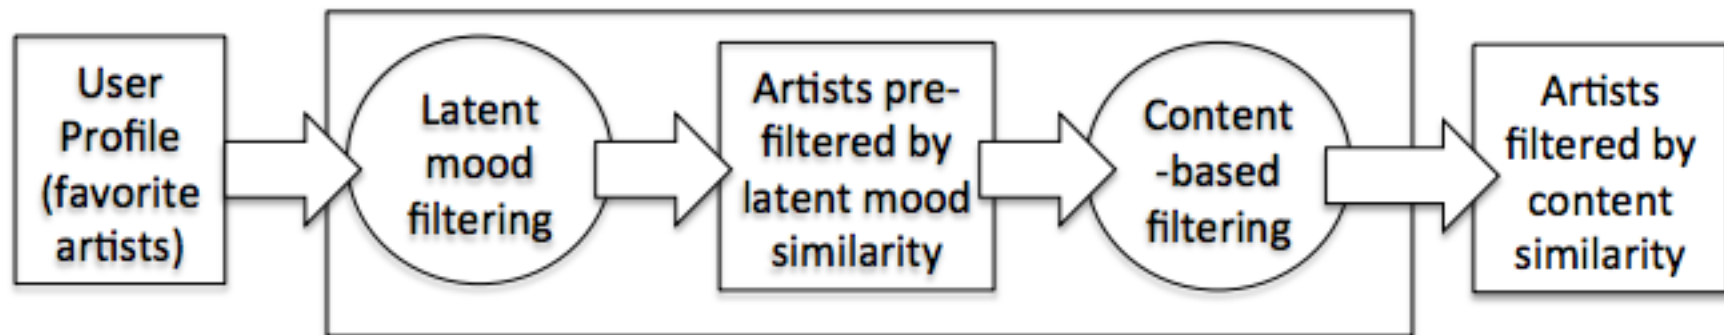
Moods and Music: the GEMS model

Category	Sub-category	No. of moods	Example moods
Sublimity	Tenderness	24	Delicate, romantic, sweet
	Peacefulness	22	Pastoral, relaxed, soothing
	Wonder	24	Happy, light, springlike
	Nostalgic	9	Dreamy, rustic, yearning
	Transcendence	10	Atmospheric, spiritual, uplifting
Vitality	Power	29	Ambitious, fierce, pulsing, intense
	Joyful activation	32	Animated, fun, playful, exciting
Unease	Tension	32	Nervous, harsh, rowdy, rebellious
	Sadness	18	Austere, bittersweet, gloomy, tragic
	Fear *	10	Spooky, nihilistic, ominous
	Lethargy *	8	Languid, druggy, hypnotic
	Repulsiveness *	10	Greasy, sleazy, trashy, irreverent
Other *	Stylistic *	19	Graceful, slick, elegant, elaborate
	Cerebral *	12	Detached, street-smart, ironic
	Mechanical *	7	Crunchy, complex, knotty

System Architecture



Hybrid Recommendation Approach

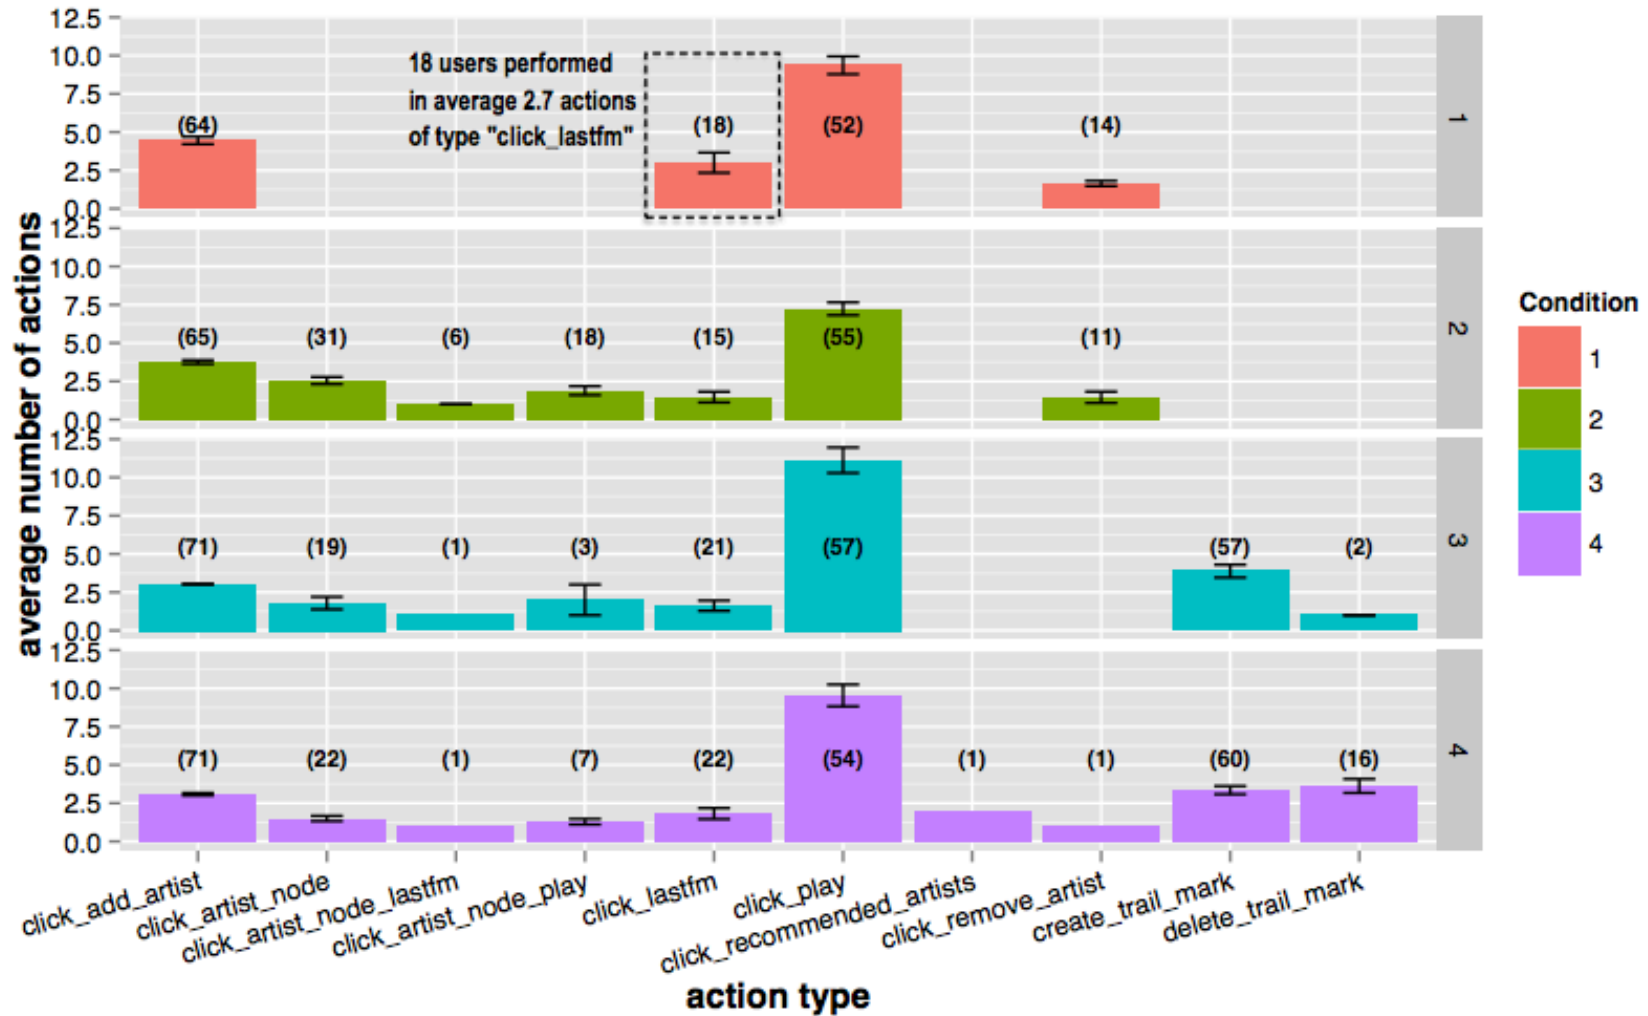


User Study



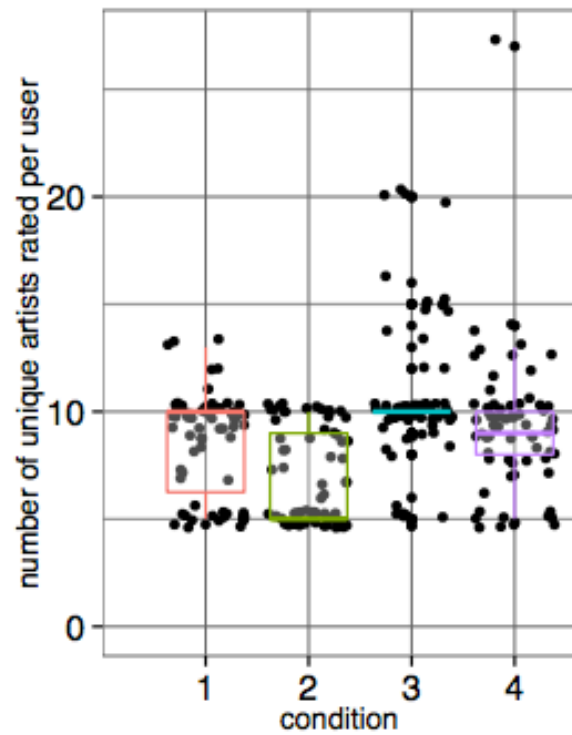
- Conducted on Mechanical Turk, 4 conditions

Feature / Condition	1	2	3	4
Profile generation	x	x	x	x
Ordered list of recommendations	x	x	x	x
Display of latent mood space		x	x	x
Navigation in latent mood space			x	x
Hybridization control			x	x
Trail based recommendations				x

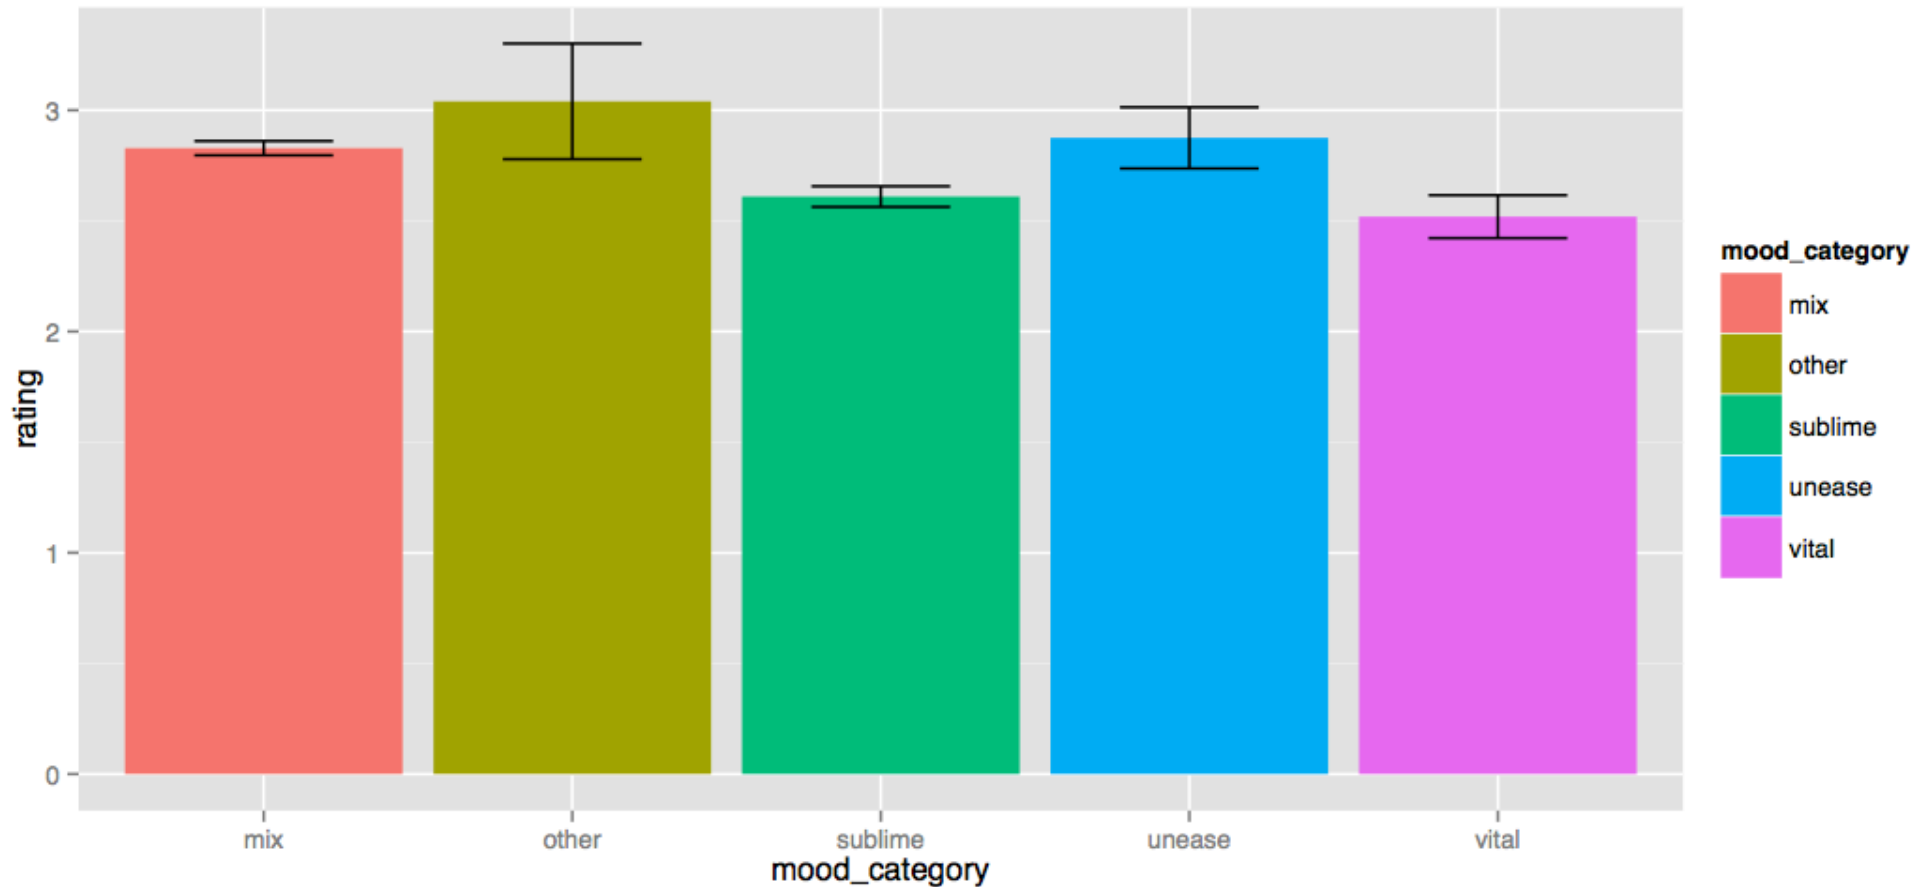
Interaction Stats



Diversity Consumption




Relation Between Ratings and Moods



Relation Between Ratings and Moods

II



Post-Study Survey

Statement	Mean agreement and standard error per condition			
	1	2	3	4
I trusted recommendations from the system	37.1 ± 3.6	44.6 ± 3.5	48.8 ± 3.5	38.4 ± 3.6
Interaction w/interface increased my trust in the recommendations	43.4 ± 3.6	47.1 ± 3.8	49.4 ± 3.8	39.2 ± 3.7
The recommendations were diverse	60.9 ± 3.3	65.3 ± 3.3	68.6 ± 3.3	59.9 ± 3.3
The interface helped me understand and compare moods of different artists	49.4 ± 3.5	55.7 ± 3.5	55.7 ± 3.3	46.3 ± 3.4
The interface helped me understand how recommendations were generated	42.8 ± 3.6	54.4 ± 3.9	58.6 ± 3.8	50.3 ± 3.7
The interface was confusing	23.1 ± 3.1	45.3 ± 4.1	46 ± 3.9	52.6 ± 3.9
Overall, the recommendations were accurate	36.2 ± 3.6	40.7 ± 3.6	49.8 ± 3.7	38.7 ± 3.5
The system was easy to use	73.9 ± 3.6	58.3 ± 3.8	63.8 ± 3.6	53.2 ± 4
By the end of the session I was satisfied with the recommendations	42.2 ± 4.1	44.2 ± 4	49.3 ± 3.9	38 ± 3.6

- Thanks!