

PREDICCIÓN DE LA POSIBILIDAD DE CALIBRACIÓN DE MODELOS DE SEGUIMIENTO VEHICULAR PARA TRAYECTORIAS CORTAS DE VEHÍCULOS INDIVIDUALES

Renata Espinosa Rudolff, Universidad de los Andes, Chile – raespinosa@miuandes.cl

Rafael Delpiano Costabal, Universidad de los Andes, Chile – rdelpiano@uandes.cl

Palabras clave: calibración, modelos de seguimiento vehicular, variabilidad de conductores

RESUMEN

El estudio de la variabilidad entre conductores requiere la calibración de modelos de seguimiento vehicular (MSV) en base a trayectorias individuales. Un obstáculo observado es que algunas trayectorias llevan a calibraciones irreales, lo que implica esfuerzo perdido.

En este paper se busca explorar un método para predecir la utilidad de una trayectoria para calibrar.

Se calibraron dos MSV para un conjunto amplio de trayectorias provenientes de bases de datos diversas; se clasificaron según sus resultados creíbles o no; se entrenó un clasificador con *random forests* para predecir dicha clasificación, y se evaluó su calidad.

Se logró una predicción satisfactoria, especialmente al asumir observable sólo un subconjunto de parámetros (80 % y 90 % de exactitud). Resultaron informativos los extremos de la aceleración, el headway promedio, y la proporcionalidad del espaciamiento a la velocidad.

1. INTRODUCCIÓN

La variabilidad de conductores es un fenómeno poco estudiado en relación con la importancia que tiene en el desempeño del tráfico, en la seguridad, y en las posibles interacciones entre vehículos autónomos y aquellos con conductores humanos.

Esta variabilidad tiene al menos dos facetas: la variabilidad entre conductores, que explica las diferencias del estilo de manejo entre un conductor y otro, y la variabilidad interna de cada conductor, que explica los cambios de comportamiento de un mismo conductor en el tiempo. La variabilidad interna suele modelarse mediante la adición de un término aleatorio a la formulación de un modelo determinístico preexistente y con conductores uniformes (Laval et al., 2014; Treiber y Kesting, 2017). La variabilidad entre conductores, por su parte, suele modelarse mediante distribuciones independientes para uno o más parámetros (Gipps, 1981; Martínez y Jin, 2020). En ambos casos,

el marco de modelación ha privilegiado los supuestos simples por sobre la validación empírica.

La variabilidad de conductores, sin embargo, ha comenzado recientemente a cobrar relevancia como materia de estudio empírica. Si antes la praxis universal era calibrar un modelo con conductores uniformes en base a variables de desempeño de tráfico microscópico, algunos autores han comenzado a plantear la calibración de parámetros para cada conductor, en base a trayectorias individuales. Punzo et al. (2021) propusieron una metodología para la calibración de modelos a partir de trayectorias individuales, recomendando, entre otras cosas, el uso del espaciamiento como fundamento de la función objetivo a optimizar. Por su parte, Zhang et al. (2021) hicieron un trabajo exhaustivo de estimación de la media y desviación estándar de cada parámetro de cuatro modelos distintos con miras a variabilidad entre conductores, y llegaron a ajustar distribuciones para variabilidad interna. En su trabajo usaron la base de datos del naturalistic driving study de Shanghai (Zhu et al., 2018), consistente en datos de largo plazo obtenidos por vehículos instrumentados. Como contrapartida, Pipino (2022) calibró el modelo de Gipps (1981) y el IDM (Treiber et al., 2000) para trayectorias individuales extraídas de la base de datos highD (Krajewski et al., 2018), que sigue a los vehículos en un segmento de autopista de poco más de 400 m, pero en algunos casos obtuvo valores poco realistas como resultado.

Esto último parece deberse al problema de identificabilidad, es decir, que algunas trayectorias no permitirían por sí solas calibrar algunos parámetros. No existe una metodología para saber si una trayectoria de corto plazo (como las de highD y las que se pueden adquirir desde videos) es buena para calibrar. Algunas trayectorias (p.ej. en equilibrio) no permitirán por sí solas distinguir parámetro alguno, mientras que otras lo harán para algunos o para todos los parámetros de un modelo concreto. Al ser la calibración un proceso iterativo relativamente lento, se busca una forma de evaluar rápidamente una trayectoria y predecir —dentro de lo posible— su utilidad para ser objeto de calibración.

En este artículo se busca i) definir un conjunto de métricas cuya apariencia desde el punto de vista técnico sugiera que pueden servir para esta predicción, y ii) ponerlas a prueba en su capacidad predictiva.

Como herramienta predictiva se emplea el random forest utilizada en el campo del aprendizaje automático (*machine learning*). Es un algoritmo de aprendizaje supervisado que se utiliza tanto para tareas de clasificación como para regresión. En el contexto de la clasificación, el Random Forest se utiliza para predecir la clase o categoría a la que pertenece una determinada instancia o muestra. Esto lo realiza combinando múltiples árboles de decisión individuales, entrenados con subconjuntos de datos diferentes y ciertas características elegidas al azar. Luego se combinan las predicciones de todos los árboles y se obtiene una predicción final.

2. MODELOS Y PARÁMETROS A CALIBRAR

Tal como se menciona más arriba, se calibrará dos modelos de seguimiento vehicular (MSV): el modelo de Gipps y el IDM.

El MSV de Gipps se define por una ecuación diferencial discreta definida como un mínimo entre dos expresiones, representativas una del seguimiento vehicular y otra del régimen de aceleración y flujo libres:

$$v_n(t + \tau) = \min \left\{ v_n(t) + 2,5a_n\tau \left(1 - \frac{v_n(t)}{V_n} \right) \sqrt{0,025 + \frac{v_n(t)}{V_n}}, \right. \\ \left. b_n\tau + \sqrt{b_n^2\tau^2 - b_n \left(2[x_{n-1}(t) - s_{n-1} - x_n(t)] - v_n(t)\tau - \frac{v_{n-1}^2(t)}{\hat{b}} \right)} \right\}, \quad (1)$$

donde $v_\bullet$ y $x_\bullet$ representan respectivamente la velocidad y posición de un vehículo, y los subíndices n y $n - 1$ identifican respectivamente al vehículo modelado y su líder. El modelo define seis parámetros que han de ser calibrados y en su formulación original propone unos valores iniciales, según se detalla en la tabla 1.

parám.	significado	unidades	v. ini.
a	aceleración máxima	ms^{-2}	1,7
b	desaceleración máxima	ms^{-2}	-3,4
$\hat{b}$	estimación de la desaceleración del líder	ms^{-2}	-3,2
s	espaciamento de taco	m	6,5
τ	tiempo de reacción	s	$\frac{2}{3}$
V	velocidad máxima	ms^{-1}	20

Tabla 1: Parámetros de Gipps y sus valores iniciales

de estos, cabe señalar que dos (a y V) influyen exclusivamente en la rama libre, tres (b , $\hat{b}$ y s) influyen exclusivamente en seguimiento vehicular, y sólo uno (τ) está presente en ambas ramas. En este trabajo no se calibrará el parámetro τ , porque complica la comparación de las métricas de calibración en una forma que amerita un análisis aparte.

Por su parte, el IDM está definido por una única ecuación diferencial, donde la aceleración depende al mismo tiempo de la comparación entre la velocidad actual y la deseada, y el *gap* (i.e. espaciamento neto, es decir, descontando la longitud del vehículo) actual y uno ideal. La ecuación, manteniendo la notación anterior, toma la siguiente forma:

$$\dot{v}_n(t) = a \left[1 - \left(\frac{v_n(t)}{v_0} \right)^\delta - \left(\frac{s_0 + Tv_n(t) + \frac{v_n(t)[v_n(t) - v_{n-1}(t)]}{2\sqrt{ab}}}{x_{n-1}(t) - l - x_n(t)} \right)^2 \right], \quad (2)$$

donde $\dot{v}_n(t)$ es la derivada de la velocidad (i.e., la aceleración) del vehículo modelado. El resto de las variables nuevas corresponde a parámetros. El modelo en su forma original define siete, según se detalla en la tabla 2.

parám.	significado	unidades	v. ini.
a	aceleración máxima	ms^{-2}	0,73
b	desaceleración deseada	ms^{-2}	1,67
v_0	velocidad deseada	ms^{-1}	33, $\bar{3}$
s_0	gap (espaciamiento neto) de taco	m	2
l	longitud de vehículo	m	5
T	headway de seguridad	s	1,6
δ	exponente de la aceleración	—	4

Tabla 2: Parámetros del IDM y sus valores iniciales

La literatura posterior (e.g. Sun et al., 2020) ha reducido estos parámetros a sólo cinco, fijando $\delta = 4$ (dado que en la mayoría de los casos el seguimiento vehicular es poco sensible a su variación) y reduciendo los parámetros de distancia (s_0 y l) a uno solo por su relación estrecha a través del espaciamiento de taco. En este trabajo, se sigue la convención de fijar *delta* y se calibra un espaciamiento de taco $s = s_0 + l$, considerando una longitud de vehículo constante.

A diferencia del modelo de Gipps, en teoría todos los parámetros pueden influir tanto en el seguimiento vehicular como en el flujo libre, pero sigue siendo cierto que algunos de ellos están más presentes en uno u otro régimen. Concretamente, a y v_0 dominan el flujo libre, mientras que b , s_0 y T lo hacen para el seguimiento vehicular.

3. DATOS DE TRAYECTORIAS INDIVIDUALES

Los datos de las trayectorias vehiculares utilizadas en el estudio se obtienen de los sets *highD* (Krajewski et al., 2018) y NGSIM (FHWA, 2011). Ambos describen exhaustivamente trayectorias de vehículos en un segmento de autopista por un período de tiempo, permitiendo estudiar cada vehículo individual y la relación sostenida con los vehículos circundantes.

En el caso de *highD*, se trata de 60 escenarios de 15 minutos de tiempo y aproximadamente 400 metros de longitud, recogidos en 6 sitios distintos del *Autobahn* alemán, de dos o tres pistas por sentido en ambos sentidos. Las trayectorias fueron extraídas desde video cenital aéreo, con una resolución temporal de 25 cuadros por segundo, y en el conjunto se observa mayoritariamente flujo libre.

Por su parte, NGSIM se trata de 2 escenarios de 45 minutos y longitudes mayores, recogidos en dos autopistas urbanas de California (US-101, I-80), de cinco y seis pistas en un único sentido. Las trayectorias fueron extraídas desde video capturado por cámaras ubicadas en azoteas de edificios, con una resolución temporal de 10 cuadros por segundo, y en ellos se observa principalmente un régimen congestionado. En el pasado, los datos de NGSIM han sido criticados por su nivel de ruido (Punzo et al., 2011; Coifman y Li, 2017; Delpiano, 2021).

Como preprocesamiento, se aisló aquellos vehículos que no cambiaron de pista durante su paso por el segmento observado, mientras tuvieron un líder a lo largo del tiempo (incluso si éste cambia-

ba), de manera de tener siempre un par líder-seguidor y minimizar el efecto de repulsión de otros vehículos circundantes.

4. METODOLOGÍA

En términos de aprendizaje de máquina, el problema se afrontó como uno de clasificación. Cada trayectoria individual fue calibrada según se detalla más adelante y fue etiquetada en función de si el valor de cada parámetro obtenido estaba o no dentro de un rango físicamente creíble. Luego se extrajo un conjunto de seis atributos, planteados como métricas significativas calculadas a partir de características medibles de las mismas trayectorias, y se procedió a entrenar *random forests* que lograran aproximar la misma clasificación.

4.1. Atributos: Métricas descriptivas de las trayectorias

Se definen seis métricas, cuyo nombre, significado y justificación técnica se detallan a continuación:

- Diferencia de velocidad, Δv : diferencia entre la máxima y mínima velocidad mostrada por el vehículo observado a lo largo de la trayectoria. Si ésta es pequeña, es más probable que el vehículo haya estado en equilibrio y cause problemas de identificabilidad.
- Aceleración mínima, a_m : el mínimo valor de la aceleración (si el vehículo desacelera, corresponderá a la máxima desaceleración). Es razonable pensar que un vehículo en equilibrio o transitando a flujo libre desacelere poco y a la vez entregue poca información que ayude a calibrar algunos de los parámetros. Como contrapartida, uno que desacelere podría entregar más información acerca de ellos.
- Diferencia de aceleraciones, Δa : como una alternativa a la anterior, también informativa en caso de aceleración libre.
- Headway estimado promedio, $\bar{x}_h$: la media temporal del headway estimado. Por rapidez de cálculo, en esta métrica y la siguiente, el headway estimado se calcula como la razón entre el espaciamiento y la velocidad instantáneos, $\frac{x_{n-1}(t)-x_n(t)}{v_n(t)}$. Si el headway es menor, es más probable que haya seguimiento vehicular; si es mayor, más probable el flujo libre. Nótese que esta estimación del headway será exacta sólo en el equilibrio, mientras que fuera de él podría errar. En cualquier caso, en situaciones fuera del equilibrio, pero en régimen de seguimiento vehicular, la restricción de cinemática de onda y el teorema del valor medio harán que la estimación sea cierta para algún punto cercano en el tiempo.
- Desviación estándar del headway estimado, s_h : si es baja, el headway varía poco y es más probable que el vehículo esté en equilibrio.
- Razón de espaciamiento, s_r/s_e : El cociente entre el espaciamiento real y uno de equilibrio estimado con parámetros genéricos: Mientras mayor sea, más probable es que haya flujo o

aceleración libres. A la inversa, mientras menor sea, más probable es que haya interacciones con el líder, que serán más intensas. Este espaciamiento de referencia se calcula como función lineal de la velocidad: $s_e(v) = s^* + v\tau^*$, con $s^* = 6$ m y $\tau^* = 1,44$ s.

4.2. Calibración

La calibración se planteó como un problema de optimización en que el espacio de búsqueda es el espacio de parámetros y la función objetivo es el ajuste de una trayectoria modelada a la trayectoria real, tomando como dato de entrada la trayectoria del líder la posición y velocidad iniciales del sujeto. Se definió unos límites para cada parámetro para la búsqueda, según se detalla en la tabla 3. Para el ajuste se usó la raíz cuadrada del error cuadrático medio (*root mean square error*, RMSE), siguiendo a Punzo et al. (2021). Para calibrar usando las trayectorias de highD se usó un algoritmo de optimización convencional; para el caso de NGSIM, fue necesaria la optimización evolutiva (heurística), de manera de superar el obstáculo del ruido.

Se plantea la hipótesis de que podría haber trayectorias que, presentando uno solo de los dos regímenes (seguimiento vehicular o libre), permitieran calibrar mejor los parámetros correspondientes a dicho régimen. En esa situación, la carga de intentar calibrar parámetros para el régimen ausente sólo incrementa el espacio de búsqueda y las posibilidades de encontrar problemas de identificabilidad. Adicionalmente Punzo et al. (2015) encontraron que el enfoque de calibración de un subconjunto de parámetros no incidía gravemente en el ajuste ni en los parámetros resultantes, particularmente cuando los parámetros excluidos inciden menos en la simulación.

En atención a lo anterior, la calibración se repitió tres veces para cada par trayectoria–modelo: i) calibrando todos los parámetros simultáneamente, ii) fijando los parámetros asociados a seguimiento vehicular y calibrando sólo los de flujo libre y iii) fijando los de flujo libre y calibrando sólo los de seguimiento vehicular.

		espacio de búsqueda			
		mín	“razonable”		máx
Gipps	a	0,1	0,5	2	10
	b	-10,0	-5	-0,5	-0,1
	$\hat{b}$	-10,0	-5	-0,5	-0,1
	s	1,0	5	11	12
	V	10,0	12	65	70
IDM	a	0,1	0,5	2	10
	b	0,1	0,5	5	10
	V	10,0	12	65	70
	s_j	3,0	4	14	22
	T	0,1	1	4	5

Tabla 3: Cotas consideradas para el espacio de búsqueda y el rango de lo razonable de cada parámetro y modelo.

4.3. Evaluación de la capacidad predictiva de las métricas

Luego de obtener los resultados de la calibración, se etiquetó cada trayectoria según si el valor de cada parámetro calibrado quedaba o no dentro de los rangos que se detallan en la tabla 3, como un *proxy* de una calibración exitosa. Al hacer esto, se redujo explícitamente —por simplicidad y acotación del trabajo— el problema de si la calibración fue exitosa, al de si los parámetros obtenidos resultan *razonables* según un criterio objetivo e informado por la experiencia, pero arbitrario. Esto lógicamente da lugar a impresiones, pero tiene el valor de objetivar el procedimiento.

Con las seis métricas calculadas para cada trayectoria, y las etiquetas para cada parámetro y subconjunto de calibración, se procedió a entrenar *random forests* con una profundidad de árbol de 6 y una población de 10 árboles. Estos hiperparámetros desacostumbradamente bajos buscan por un lado minimizar la probabilidad de sobreajuste, y por otro dejar abierta la posibilidad futura de análisis e incluso de clasificación manual. Este trabajo derivado se dejó, sin embargo, fuera del alcance de la presente investigación. Como resultado, se evaluó la capacidad del bosque de árboles de decisión resultante de predecir el etiquetado de cada parámetro para cada trayectoria. Esta evaluación se hizo por vía de comparar el etiquetado real con el predicho a través de los indicadores clásicos de sensibilidad, especificidad y exactitud (v. tabla 4), además de obtener el valor de la importancia relativa de cada métrica en la predicción de la respectiva etiqueta. Para efectos de los cálculos se consideró como *positivo* la obtención de un parámetro calibrado dentro del rango, y *negativo* si estaba fuera de él.

Indicador	Expresión
Sensibilidad (<i>sensitivity</i>)	$\frac{TP}{P}$
Especificidad (<i>specificity</i>)	$\frac{TN}{N}$
Exactitud (<i>accuracy</i>)	$\frac{TP+TN}{P+N}$

P: positivo (parámetros calibrados dentro del rango); N: negativo

T•: la predicción es • y coincide con el resultado de la calibración real

Tabla 4: Indicadores reportados para el desempeño de la predicción

5. RESULTADOS

Las tablas 5 a 8 resumen los resultados más relevantes de los predictores resultantes.

La tabla 5 muestra los resultados de la predicción para las calibraciones del modelo de Gipps en los datos de *highD*. Salvo para la velocidad máxima, la calidad de la predicción es baja. Destaca la capacidad predictiva de la razón de espaciamiento s_r/s_e , y en menor medida, la del headway estimado promedio $\bar{x}_h$.

La tabla 6 muestra los resultados de la predicción para las calibraciones del modelo de Gipps en los datos de NGSIM. Se observa una mayor calidad de la predicción para los parámetros asociados a la congestión, y también para la aceleración, mientras que la calidad de la predicción de la velocidad

Parámetro		a	v	b	s	$\hat{b}$
Sensibilidad		71 %	86 %	63 %	62 %	48 %
Especificidad		45 %	60 %	52 %	51 %	63 %
Exactitud		51 %	80 %	57 %	56 %	53 %
Importancia	Δv	17,84 %	14,55 %	5,54 %	7,37 %	8,68 %
	a_m	10,47 %	27,65 %	12,15 %	11,96 %	6,36 %
	Δa	1,90 %	7,05 %	11,37 %	27,33 %	11,20 %
	$\bar{x}_h$	15,11 %	1,34 %	43,82 %	27,93 %	9,67 %
	s_h	2,84 %	7,48 %	4,14 %	9,76 %	12,74 %
	s_r/s_e	51,82 %	41,91 %	22,99 %	15,65 %	51,34 %

Tabla 5: Resultados de la predicción, datos de *highD*, modelo de Gipps, calibración de todos los parámetros simultáneamente.

máxima empeora. Esto es consistente con el hecho de que NGSIM retrata más congestión, y situaciones de tráfico fuera del equilibrio. Resalta la capacidad predictiva de la aceleración mínima a_m y su complementariedad con la diferencia de aceleraciones extremas Δa . La razón de espaciamiento aquí cumple un rol menor, posiblemente porque es menos necesario distinguir entre congestión y flujo libre.

Parámetro	a	v	b	s	$\hat{b}$	
Sensibilidad	83 %	70 %	85 %	63 %	75 %	
Especificidad	84 %	66 %	84 %	59 %	55 %	
Exactitud	84 %	68 %	88 %	60 %	59 %	
Importancia	Δv	13,17 %	26,15 %	13,43 %	22,74 %	23,28 %
	a_m	53,83 %	20,88 %	66,91 %	15,39 %	30,00 %
	Δa	14,39 %	33,55 %	13,81 %	34,38 %	24,44 %
	$\bar{x}_h$	6,80 %	7,30 %	2,16 %	8,84 %	8,94 %
	s_h	4,71 %	5,82 %	1,02 %	7,63 %	5,89 %
	s_r/s_e	7,09 %	6,29 %	2,67 %	11,02 %	7,43 %

Tabla 6: Resultados de la predicción, datos de NGSIM, modelo de Gipps, calibración de todos los parámetros simultáneamente.

La tabla 7 muestra los resultados para la misma calibración anterior, pero cuando se calibra por subconjuntos según régimen (seguimiento vehicular o libre). Todas las predicciones resultan mejores o iguales al caso en que se calibran todos los parámetros simultáneamente, lo que es consistente con una baja distinguibilidad de los parámetros en trayectorias cortas. La aceleración mínima a_m cobra una importancia relativa mayor como predictor.

La tabla 8 resume los resultados de la predicción para las calibraciones del IDM en las trayectorias de *highD*. Se observa un desempeño comparable al anterior, con resultados algo menos exitosos para los parámetros asociados al seguimiento vehicular, como era de esperar para el conjunto de datos.

	Parámetro	flujo libre		congestión		
		a	v	b	s	$\hat{b}$
	Sensibilidad	86 %	90 %	77 %	98 %	92 %
	Especificidad	83 %	93 %	83 %	99 %	99 %
	Exactitud	83 %	91 %	83 %	98 %	96 %
Importancia	Δv	27,00 %	14,03 %	20,09 %	9,70 %	9,24 %
	a_m	38,83 %	46,72 %	45,05 %	70,38 %	75,89 %
	Δa	20,08 %	32,83 %	16,09 %	14,75 %	8,48 %
	$\bar{x}_h$	3,60 %	2,28 %	8,62 %	2,39 %	3,23 %
	s_h	5,56 %	2,09 %	4,87 %	0,65 %	1,28 %
	s_r/s_e	4,93 %	2,05 %	5,29 %	2,01 %	1,88 %

Tabla 7: Resultados de la predicción, datos de NGSIM, modelo de Gipps, calibración de los parámetros por régimen.

	Parámetro	flujo libre		congestión		
		a	v	T	b	s
	Sensibilidad	82 %	92 %	91 %	90 %	78 %
	Especificidad	88 %	87 %	89 %	90 %	84 %
	Exactitud	84 %	90 %	90 %	90 %	78 %
Importancia	Δv	0,75 %	0,92 %	0,92 %	2,21 %	2,15 %
	a_m	3,06 %	3,09 %	0,39 %	3,55 %	2,18 %
	Δa	2,48 %	2,68 %	1,69 %	3,20 %	1,47 %
	$\bar{x}_h$	56,92 %	56,13 %	41,92 %	34,86 %	60,03 %
	s_h	4,91 %	4,75 %	4,67 %	2,07 %	9,14 %
	s_r/s_e	31,88 %	32,43 %	50,41 %	54,12 %	25,04 %

Tabla 8: Resultados de la predicción, datos de *highD*, *Intelligent Driver Model* (IDM), calibración de los parámetros por régimen.

6. DISCUSIÓN

El presente trabajo muestra que fue posible predecir parcialmente la factibilidad de calibrar los parámetros de los modelos de Gipps e IDM para trayectorias individuales con la ayuda de métricas simples calculables directamente a partir de la misma trayectoria.

Es evidente que no cualquier trayectoria corta sirve para calibrar todos los parámetros de un modelo. Esta idea resulta refrendada por la frecuente aparición de valores físicamente inverosímiles como resultado de la calibración. Al ser la calibración un proceso de optimización, y por lo tanto requerir de múltiples iteraciones y evaluaciones, resulta deseable la capacidad de discriminar rápidamente aquellas trayectorias que valga la pena calibrar de las que resultarán una pérdida de tiempo.

El problema de identificabilidad de los parámetros puede ser abordado parcialmente calibrando sólo un subconjunto de ellos. La calibración sólo de los parámetros que inciden más directamente en el seguimiento vehicular o sólo de aquellos que afectan más directamente al régimen de velocidad o aceleración libre resultó más predecible. Esto además es consistente con la idea de que probablemente una proporción grande de trayectorias cortas como las de los conjuntos de datos estudiados sólo presente uno de estos regímenes, y por lo tanto haga poco o nada identificables los parámetros que se usan menos.

A la idea de seleccionar los parámetros a calibrar por régimen también puede añadirse para explorar la de eliminar aquellos parámetros que incidan menos según la situación para la que se requiera dicha calibración. Esto extiende la idea de Punzo et al. (2015) en el sentido de el análisis de sensibilidad del modelo a los parámetros puede variar según las circunstancias que se quiera simular.

Entre las métricas propuestas, resulta significativo que la razón de espaciamiento s_r/s_e y el *headway* estimado promedio $\bar{x}_h$ cobran importancia en highD pero no en NGSIM. Esto puede deberse a que estas métricas ayudan a discriminar entre el régimen microscópico libre y de seguimiento vehicular: la congestión recogida en NGSIM da poco lugar a ese primer régimen, mientras que el régimen macroscópico de flujo libre de highD sí permite interacciones entre vehículos, que en parte de su trayectoria entran en un régimen microscópico de seguimiento vehicular.

Para NGSIM, en tanto, la aceleración mínima a_m y la diferencia de aceleración Δ_a cobran relevancia en la predicción. Esto es consistente con la idea de que entre más cerca esté el equilibrio, más difícil se hace la identificabilidad.

Se dijo que el hecho de haber usado un rango de valores como criterio de éxito de la calibración da lugar a imprecisiones. Por ejemplo, una situación de equilibrio en congestión, en que espaciamiento, headway y velocidad se mantienen constantes durante la observación, da lugar a un conjunto infinito de soluciones de muy buen ajuste. Este conjunto incluye las que consideran el parámetro de velocidad máxima igual a la única velocidad observada, lo cual no sería compatible con la misma congestión. Esto es consistente con el hecho de que el parámetro mejor predicho en ambos modelos es precisamente ése, y podría ser una señal de sobreajuste, sobre todo en la calibración por régimen (v. tablas 7 y 8).

Como posible idea de investigación futura, sería interesante evaluar en qué medida los clasificadores entrenados aquí son extrapolables, por ejemplo, a trayectorias más largas y cómo se comparan las calibraciones resultantes a las efectuadas con otras técnicas.

De la misma manera, sería de interés un análisis más detallado de los árboles resultantes para estudiar si es posible extraer criterios simples de clasificación de trayectorias aptas para la calibración.

Finalmente, sería útil explorar criterios más directos para declarar el éxito de una calibración.

REFERENCIAS

- Coifman, B., y Li, L. (2017, noviembre). A critical evaluation of the Next Generation Simulation (NGSIM) vehicle trajectory dataset. **Transportation Research Part B: Methodological**, 105, 362–377. Descargado 2019-01-30, de <http://www.sciencedirect.com/science/article/pii/S0191261517300838> doi: 10.1016/j.trb.2017.09.018
- Delpiano, R. (2021, agosto). Understanding the Lateral Dimension of Traffic: Measuring and Modeling Lane Discipline. **Transportation Research Record: Journal of the Transportation Research Board**, 036119812110318. Descargado 2021-08-03, de <http://journals.sagepub.com/doi/10.1177/03611981211031884> doi: 10.1177/03611981211031884
- FHWA. (2011, diciembre). **Traffic Analysis Tools, Next Generation Simulation - FHWA Operations**. Descargado 2011-12-19, de <http://ops.fhwa.dot.gov/trafficanalysistools/ngsim.htm>
- Gipps, P. (1981, abril). A behavioural car-following model for computer simulation. **Transportation Research Part B: Methodological**, 15 (2), 105–111. Descargado de <http://www.sciencedirect.com/science/article/pii/0191261581900370> (Number: 2) doi: 10.1016/0191-2615(81)90037-0
- Krajewski, R., Bock, J., Kloeker, L., y Eckstein, L. (2018, octubre). The highD Dataset: A Drone Dataset of Naturalistic Vehicle Trajectories on German Highways for Validation of Highly Automated Driving Systems. En **2018 IEEE 21st International Conference on Intelligent Transportation Systems (ITSC)**. Descargado 2019-01-22, de <https://arxiv.org/abs/1810.05642v1>
- Laval, J. A., Toth, C. S., y Zhou, Y. (2014). A parsimonious model for the formation of oscillations in car-following models. **Transportation Research Part B: Methodological**, 70, 228–238. Descargado 2014-11-03, de <http://www.sciencedirect.com/science/article/pii/S0191261514001581> doi: 10.1016/j.trb.2014.09.004
- Martínez, I., y Jin, W.-l. (2020, enero). Stochastic LWR model with heterogeneous vehicles: Theory and application for autonomous vehicles. **Transportation Research Procedia**, 47, 155–162. Descargado 2023-04-22, de <https://www.sciencedirect.com/science/article/pii/S2352146520302817> doi: 10.1016/j.trpro.2020.03.088

- Pipino, V. (2022). **Relaciones entre características de conductores, mediante la calibración de modelo de seguimiento vehicular** (Undergraduate). Universidad de los Andes, Chile.
- Punzo, V., Borzacchiello, M. T., y Ciuffo, B. (2011, diciembre). On the assessment of vehicle trajectory data accuracy and application to the Next Generation SIMulation (NGSIM) program data. **Transportation Research Part C: Emerging Technologies**, 19 (6), 1243–1262. Descargado 2018-07-18, de <http://www.sciencedirect.com/science/article/pii/S0968090X10001701> (Number: 6) doi: 10.1016/j.trc.2010.12.007
- Punzo, V., Montanino, M., y Ciuffo, B. (2015, febrero). Do We Really Need to Calibrate All the Parameters? Variance-Based Sensitivity Analysis to Simplify Microscopic Traffic Flow Models. **IEEE Transactions on Intelligent Transportation Systems**, 16 (1), 184–193. (Conference Name: IEEE Transactions on Intelligent Transportation Systems) doi: 10.1109/TITS.2014.2331453
- Punzo, V., Zheng, Z., y Montanino, M. (2021, julio). About calibration of car-following dynamics of automated and human-driven vehicles: Methodology, guidelines and codes. **Transportation Research Part C: Emerging Technologies**, 128, 103165. Descargado 2023-01-20, de <https://www.sciencedirect.com/science/article/pii/S0968090X21001832> doi: 10.1016/j.trc.2021.103165
- Sun, J., Zheng, Z., y Sun, J. (2020, diciembre). The relationship between car following string instability and traffic oscillations in finite-sized platoons and its use in easing congestion via connected and automated vehicles with IDM based controller. **Transportation Research Part B: Methodological**, 142, 58–83. Descargado 2023-07-27, de <https://www.sciencedirect.com/science/article/pii/S0191261520304112> doi: 10.1016/j.trb.2020.10.004
- Treiber, M., Hennecke, A., y Helbing, D. (2000). Congested traffic states in empirical observations and microscopic simulations. **Physical Review E**, 62 (2), 1805–1824. Descargado 2013-01-23, de <http://link.aps.org/doi/10.1103/PhysRevE.62.1805> (Number: 2) doi: 10.1103/PhysRevE.62.1805
- Treiber, M., y Kesting, A. (2017). The Intelligent Driver Model with Stochasticity -New Insights Into Traffic Flow Oscillations. **Transportation Research Procedia**, 23, 174–187. Descargado 2018-05-28, de <http://linkinghub.elsevier.com/retrieve/pii/S2352146517302880> doi: 10.1016/j.trpro.2017.05.011
- Zhang, D., Chen, X., Wang, J., Wang, Y., y Sun, J. (2021, julio). A comprehensive comparison study of four classical car-following models based on the large-scale naturalistic driving experiment. **Simulation Modelling Practice and Theory**, 102383. Descargado 2021-08-12, de <https://www.sciencedirect.com/science/article/pii/S1569190X21000927> doi: 10.1016/j.simpat.2021.102383
- Zhu, M., Wang, X., Tarko, A., y Fang, S. (2018, agosto). Modeling car-following behavior on urban expressways in Shanghai: A naturalistic driving study. **Transportation Research Part C: Emerging Technologies**, 93, 425–445. Descargado 2019-01-31, de <http://www.sciencedirect.com/science/article/pii/S0968090X18308635> doi: 10.1016/j.trc.2018.06.009