

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

Renata Espinosa¹, Rafael Delpiano^{1*}

¹ Universidad de los Andes, Chile

*Autor para correspondencia:
rdelpiano@uandes.cl

RESUMEN

El estudio de la variabilidad de conductores (i.e., diferencias de estilo de conducción de un conductor a otro o en el tiempo) requiere calibrar modelos de seguimiento vehicular (MSV) utilizando trayectorias individuales, lo que es un proceso costoso. Un problema que ocurre a menudo, es que la calibración de algunas trayectorias genera parámetros con valores irreales. Para enfrentar este problema, en este artículo se analiza un método para predecir la potencial utilidad de utilizar una trayectoria dada al calibrar.

Para esto, se calibraron dos MSV utilizando un conjunto amplio de trayectorias provenientes de bases de datos diversas. Las calibraciones obtenidas se clasificaron según si sus resultados eran realistas; se entrenó un clasificador *random forests* para predecir clasificaciones realistas, y se evaluó la calidad de las predicciones generadas.

Se logró predicciones satisfactorias, especialmente al asumir como observable a sólo un subconjunto de parámetros (78% a 98% de exactitud). Las métricas de evaluación más importantes fueron la aceleración máxima y mínima, el intervalo promedio entre vehículos (*headway*), y la razón entre el espaciamiento y la velocidad

Palabras clave Modelos de seguimiento vehicular, calibración, *random forest*.

ABSTRACT

Studying variability between drivers involves the time-consuming process of calibrating car-following models based on individual vehicle trajectories. A problem often arising in the process is that the calibration of some trajectories generates unrealistic parameter values. To address this problem, the present paper explores a method of predicting the potential utility of calibrating a given trajectory.

The method is evaluated under both the Gipps model and the intelligent driver model for a large set of trajectories from two different databases. The model calibrations obtained are classified according to whether they are realistic; a random forest classifier was trained to predict realistic classifications, and the quality of the predictions generated was then evaluated on that basis.

The predictions were found to be satisfactory, especially when only a subset of the parameters was assumed to be observable, with accuracies ranging from 78% to 98%. The evaluation metrics with the greatest relative importance were found to be minimum and maximum acceleration, average time headway, and the ratio of spacing to speed.

Keywords *D*Car-following models, calibration, random forest.

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 calibrar 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 en el caso de cuatro modelos distintos y lograron ajustar distribuciones para la variabilidad entre conductores. En su trabajo usaron la base de datos del *naturalistic driving study* de Shanghái (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 *Intelligent Driver Model* (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 algunos cientos de metros (como las de *highD* y las que se pueden adquirir desde videos) es buena para calibrar. Algunas trayectorias (e.g., 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 clasificador *random forest* (Breiman, 2001) utilizado en el campo del aprendizaje automático (*machine learning*). 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, por ser dos de los más citados y utilizados en el área. El MSV de Gipps plantea una ecuación diferencial definida como un mínimo entre dos expresiones, representativas una del seguimiento vehicular (es decir, cuando el vehículo modelado se ve restringido por un líder) y otra del régimen de conducción libre (cuando puede mantener su velocidad deseada o acelerar libremente hasta ella porque no existe dicha restricción):

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

donde v . y x . 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 los valores iniciales, que se muestran en la Tabla 1.

Tabla 1 Parámetros de Gipps y sus valores iniciales

Parámetro	Significado	Unidades	Valor inicial
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 mínimo, de embotellamiento, o de taco	m	6,5
τ	tiempo de reacción	s	2/3
V	velocidad máxima	ms^{-1}	20

Dos de estos (a y V) influyen exclusivamente en el término correspondiente a la conducción 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 ameritaría 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 la brecha (*gap*), esto es, el espaciamiento neto descontando la longitud del vehículo, actual y una ideal. La ecuación, manteniendo la notación anterior, toma la siguiente forma:

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

donde $\dot{v}_n(t)$ es la derivada de la velocidad (i.e., la aceleración) del vehículo modelado. El resto de las variables nuevas son parámetros. El modelo, en su forma original, define siete (Treiber et al., 2000), según se detalla en la Tabla 2.

Tabla 2 Parámetros del IDM y sus valores iniciales

Parámetro	Significado	Unidades	Valor inicial
a	aceleración máxima	ms^{-2}	0,73
b	desaceleración deseada	ms^{-2}	1,67
v_0	velocidad deseada	ms^{-1}	33,3...
s_0	espaciamiento neto de embotellamiento o taco	m	2
l	longitud de vehículo	m	5
T	<i>headway</i> de seguridad	s	1,6
δ	exponente de la aceleración	—	4

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, debido a su relación estrecha a través del espaciamiento de embotellamiento s . En este trabajo, se sigue la convención de fijar δ y se calibra $s = s_0 + l$, 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 la conducción libre, pero sigue siendo cierto que algunos de ellos están más presentes en uno u otro régimen. Concretamente, a y v_0 dominan la conducción 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 conjuntos *highD* (Krajewski *et al.*, 2018) y NGSIM (FHWA, 2011). Ambos describen exhaustivamente trayectorias de vehículos en un segmento de autopista por un período, 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 y aproximadamente 400 metros de longitud, recogidos en seis 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 considera dos 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 ruido (Coifman y Li, 2017; Delpiano, 2021; Punzo *et al.*, 2011), es decir, por errores de medición locales que distorsionan el análisis fino pero no el global.

Como preprocesamiento, se aisló aquellos vehículos que no cambiaron de pista durante su paso por el segmento observado, mientras tuvieron un antecesor a lo largo del tiempo (incluso si éste cambiaba), de manera de tener siempre un par líder-seguidor que permitiera determinar si existía o no seguimiento vehicular, y minimizar el efecto de repulsión de otros vehículos circundantes. A modo de ejemplo, en *highD*, de 110.516 vehículos reportados, se identificó 93.301 que no se cambiaban de pista. Para 92.015 de ellos, se pudo identificar, además, al vehículo antecesor durante una parte de la trayectoria, lo que corresponde a un 83% del total. En dicha base de datos, los segmentos observados son invariablemente de 400 m de longitud, y los vehículos los recorren en 14,52 s en promedio. En NGSIM las extensiones de observación son mayores, distintas para cada subconjunto de datos, pero nunca mayores a 700 m. En cualquier caso, las velocidades son menores y no es infrecuente ver trayectorias de 100 s de duración o más.

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, que fueron calculadas a partir de características medibles de las mismas trayectorias; con esto se procedió a entrenar *random forests* que logran aproximar la misma clasificación.

4.1 Atributos: Métricas descriptivas de las trayectorias

Se definió 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 (i.e., a la misma velocidad que su antecesor y a una distancia tal que resulte cómoda, no haciendo deseable acelerar ni desacelerar) 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 conduciendo libremente 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 : diferencia entre la aceleración máxima y mínima del vehículo en el trayecto observado, como una alternativa a la métrica 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, $\frac{x_{n-1}(t) - x_n(t)}{v_n(t)}$. El *headway* se relaciona inversamente con el flujo y entrega información parcial sobre el estado de tráfico. 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 era el espacio de parámetros y la función objetivo 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 la búsqueda de cada parámetro, 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 una optimización evolutiva (heurística), a fin de superar el obstáculo del ruido.

Se planteó la hipótesis que podrían haber trayectorias que, presentando uno solo de los dos regímenes (seguimiento vehicular o conducción 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 valores 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 conducción libre y (iii) fijando los de conducción libre y calibrando sólo los de seguimiento vehicular. Cada vez que se fijó un parámetro, se hizo con el valor inicial propuesto en las referencias originales (ver Tablas 1 y 2).

Tabla 3 Cotas consideradas para el espacio de búsqueda y el rango razonable de cada parámetro

		Espacio de Búsqueda			
		Razonable			
		mín	mín	máx	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

4.3 Evaluación de la capacidad predictiva de las métricas

Tras 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 detallados en la Tabla 3, como un *proxy* de una calibración exitosa. En realidad, lo que se logra es señalar con certeza ocasiones en que la calibración falla, y otras en que no se puede afirmar que haya fallado. 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 resultaban *razonables* según un criterio que, si bien es arbitrario, está informado por la experiencia y es cuantificable. Al tratarse de variables continuas sin un límite teórico ni práctico reportados en la literatura, perfectamente podría haberse escogido límites ligeramente distintos; esta *arbitrariedad* es sin embargo necesaria para posibilitar la clasificación. Ahora, aunque lógicamente da lugar a imprecisiones, tiene el valor de objetivar el procedimiento. Lo importante es que exista un espacio de búsqueda que incluya resultados incorrectos o físicamente inverosímiles y englobe al rango considerado razonable, a fin de dar a la optimización la posibilidad de converger fuera de él.

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 seis y una población de diez 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.

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 comparando el etiquetado real con el predicho a través de los indicadores clásicos de *sensibilidad*, *especificidad* y *exactitud* (ver Tabla 4), además de obtener el valor de la importancia relativa de cada métrica en la predicción de la respectiva etiqueta (entendida como a qué porcentaje de la exactitud contribuyó cada métrica). Para efecto de los cálculos, se consideró como *positivo* la obtención de un parámetro calibrado dentro del rango, y *negativo* si estaba fuera de él.

Tabla 4 Indicadores reportados para el desempeño de la predicción.

Indicador	Expresión
Sensibilidad (<i>sensitivity</i>)	TP/P
Especificidad (<i>specificity</i>)	TN/N
Exactitud (<i>accuracy</i>)	(TP+TN)/(P+N)

P: positivo (parámetros calibrados dentro del rango); N: negativo; TP y TN: verdadero positivo y verdadero negativo: la predicción es P o N (según sea el caso) y coincide con el resultado de la calibración real

5. RESULTADOS

Las Tablas 5 a 8 resumen los resultados más relevantes de los predictores resultantes. En particular, la Tabla 5 muestra los resultados de predicción para las calibraciones del modelo de Gipps usando 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 usando los datos de NGSIM. Se observa una mayor calidad de la predicción para los parámetros asociados a la congestión, y también para la aceleración, pero la calidad de la predicción de la velocidad máxima empeora. Esto es consistente con el hecho que NGSIM retrata más congestión, y situaciones de tráfico fuera del equilibrio. También resalta la capacidad predictiva de la aceleración mínima a_m y cómo ésta se complementa con la diferencia de aceleraciones extremas Δa en la predicción. La razón de espaciamiento cumple un rol menor en este caso, posiblemente porque es menos necesario distinguir entre congestión y flujo libre.

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

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

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

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.

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

		Conducción libre		Congestión		
Parámetro		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

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.

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

		Conducción libre		Congestión		
Parámetro		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

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 tener la capacidad de discriminar rápidamente entre 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 de sólo los parámetros que inciden más directamente en el seguimiento vehicular o sólo de aquellos que afectan más directamente al régimen de conducción libre, resultó más predecible. Esto, además, es consistente con la idea 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 posibilidad 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 que la sensibilidad de los modelos a sus parámetros varía drásticamente según las circunstancias (e.g., flujo libre o congestión, equilibrio, ondas de choque, etc.) 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 de conducción libre y de seguimiento vehicular: la congestión recogida en NGSIM da poco lugar a ese primer régimen, mientras que el 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 Δa 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.

Ya se mencionó que el haber usado un rango de valores como criterio de éxito de la calibración puede dar 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 que el parámetro mejor predicho en ambos modelos es precisamente ese, y podría ser una señal de sobreajuste, sobre todo en la calibración por régimen (ver 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

critérios simples de classificação de trajetórias aptas para a calibração. Finalmente, seria útil explorar critérios mais directos para declarar o êxito de uma calibração.

REFERENCIAS

Breiman, L. (2001) Random forests. *Machine Learning* **45**,5–32.

Coifman, B. y Li, L. (2017) A critical evaluation of the Next Generation Simulation (NGSIM) vehicle trajectory dataset. *Transportation Research Part B: Methodological* **105**, 362–377.

Delpiano, R. (2021) Understanding the lateral dimension of traffic: measuring and modelling lane discipline. *Transportation Research Record* **2675**, 1030–1042.

FHWA (2011) Next Generation Simulation. Traffic Analysis Tools Program, Federal Highway Administration, US Department of Transportation, Washington, D.C.
<http://ops.fhwa.dot.gov/trafficanalysisistools/ngsim.htm>

Gipps, P.G. (1981) A behavioural car-following model for computer simulation. *Transportation Research Part B: Methodological* **15**, 105-111.

Krajewski, R., Bock, J., Kloeker, L. y Eckstein, L. (2018) The highD dataset: a drone dataset of naturalistic vehicle trajectories on German highways for validation of highly automated driving systems. *IEEE 21st International Conference on Intelligent Transportation Systems (ITSC)*. 4-7 noviembre 2018, Maui, EE.UU.

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.

Martínez, I. y Jin, W. (2020) Stochastic LWR model with heterogeneous vehicles: theory and application for autonomous vehicles. *Transportation Research Procedia* **47**, 155–162.

Pipino, V. (2022) Relaciones entre características de conductores, mediante la calibración de modelo de seguimiento vehicular. Memoria de título, Universidad de los Andes, Chile.

Punzo, V., Borzacchiello, M.T. y Ciuffo, B. (2011) 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**, 1243-1262.

Punzo, V., Montanino, M. y Ciuffo, B. (2015) 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**, 184–193.

Punzo, V., Zheng, Z. y Montanino, M. (2021) About calibration of car-following dynamics of automated and human-driven vehicles: methodology, guidelines and codes. *Transportation Research Part C: Emerging Technologies* **128**, 103165.

Sun, J., Zheng, Z. y Sun, J. (2020) 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.

Treiber, M., Hennecke, A. y Helbing, D. (2000) Congested traffic states in empirical observations and microscopic simulations. *Physical Review E* **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.

Zhang, D., Chen, X., Wang, J., Wang, Y. y Sun, J. (2021) A comprehensive comparison study of four classical car-following models based on the large-scale naturalistic driving experiment. *Simulation Modelling Practice and Theory* **113**, 102383.

Zhu, M., Wang, X., Tarko, A. y Fang, S. (2018). Modelling car-following behaviour on urban expressways in Shanghai: a naturalistic driving study. *Transportation Research Part C: Emerging Technologies* **93**, 425–445.