

FORMATO VERIFICACIÓN TÉCNICO MECÁNICA PARA VEHÍCULOS

No: 00001419-2511

CDA BOGOTÁ SEDE
NORTE 170 TOBERIN
NIT 9016353349
CL 166 22-13 BOGOTÁ Tel
3143968942
BOGOTÁ



FECHA

Fecha de prueba: Nombre o razón social:
2025-11-11 NICOLI HERNANDEZ

Dirección: CL161A 8B 20

Placa: TFP679

Marca: VOLKSWAGEN

Servicio: PÚBLICO

No Licencia Tránsito: 10035265824

Nombre o razón social:
NICOLI HERNANDEZ

Teléfono:

3224756256

Documento de identidad:
CC. (X) NIT. () CE. ()

No. 1000149682

Ciudad:

BOGOTÁ

Departamento:

DISTRITO CAPITAL

DATOS DEL VEHICULO

Línea: TRANSPORTER T5

Clase: MICROBUS

Modelo: 2012

Cilindrada: 1968

Kilometraje: 285062

Combustible: DIESEL

Color: BLANCO CANDY

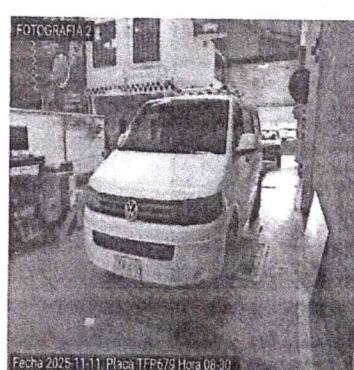
Empresa:

Conductor:

NICOLI HERNANDEZ



Fecha 2025-11-11, Placa TFP679 Hora 08:25



Fecha 2025-11-11, Placa TFP679 Hora 08:30

Suspensión (Si aplica)

Delantera Izquierda	Valor 55	Delantera Derecha	Valor 52	Trasera Izquierda	Valor 62	Trasera Derecha	Valor 68	Mínimo 40	Unidad %
Frenos									
Eficacia Total	Mínimo 52,7	Unidad % 50	Eje 1 Izquierdo	Fuerza 2707	Peso 4267	Unidad N	Eje 1 Derecho	Fuerza 2758	Peso 4218
			Eje 2 Izquierdo	1348	3434	N	Eje 2 Derecho	1438	3728
Eficacia Auxiliar	Mínimo 13,8*	Unidad % 18	Eje 3 Izquierdo				Eje 3 Derecho		
			Eje 4 Izquierdo				Eje 4 Derecho		
			Eje 5 Izquierdo				Eje 5 Derecho		

Desviación Lateral

Eje 1	-2,8	Eje 2	1,5	Eje 3	Eje 4	Eje 5	Máximo	± 10	Unidad	(m/km)
Inspección Sensorial										

ITEMS INSPECCIONADOS EN LA REVISIÓN PREVENTIVA:

Identificación reglamentaria	CUMPLE	Distintivo de la empresa	CUMPLE	Anclaje sillas	CUMPLE
Estado tubos escape	CUMPLE	Aseo General	CUMPLE	Espejos	CUMPLE
Pernos	CUMPLE	Soportes	CUMPLE	Rotulas Superiores	CUMPLE
Rotulas Inferiores	CUMPLE	Resortes o Ballestas	CUMPLE	Amortiguadores	CUMPLE
Tijeras	CUMPLE	Limpiaparabrisas	CUMPLE	Retrovisores	CUMPLE
Pito	CUMPLE	Dispositivo de velocidad	CUMPLE	Parabrisas	CUMPLE
Ventanillas	CUMPLE	Puertas	CUMPLE	Cinturones de Seguridad	CUMPLE
Salidas emergencia y Martillo	CUMPLE	Direccionales	CUMPLE	Stop	CUMPLE
Reversa	CUMPLE	Luz de parqueo	CUMPLE	Luz Interna	CUMPLE
Luz Placa	CUMPLE	Luces Altas	CUMPLE	Luces Bajas	CUMPLE
Indicadores de tablero	CUMPLE	Terminales Batería	CUMPLE	Anclaje de batería	CUMPLE
Desempeñador	CUMPLE	Cruceta	CUMPLE	Linterna	CUMPLE
Triángulos	CUMPLE	Banderola	CUMPLE	Tacos	CUMPLE
Llanta de repuesto	CUMPLE	Gato	CUMPLE	Herramienta	CUMPLE
Extintor	CUMPLE	Botiquín	CUMPLE	Señales de advertencia	CUMPLE
Eje1 llanta Derecha	CUMPLE	Eje1 llanta Izquierda	CUMPLE	Eje2 llanta Derecha	CUMPLE
Eje2 llanta Izquierda	CUMPLE	Eje3 llanta Derecha	CUMPLE	Eje3 llanta Izquierda	CUMPLE
Eje4 llanta Derecha	CUMPLE	Eje4 llanta Izquierda	CUMPLE	Eje5 llanta Derecha	CUMPLE
Eje5 llanta Izquierda	CUMPLE	Eje1 Rin Derecho	CUMPLE	Eje1 Rin Izquierdo	CUMPLE
Eje2 Rin Derecho	CUMPLE	Eje2 Rin Izquierdo	CUMPLE	Eje3 Rin Derecho	CUMPLE
Eje3 Rin Izquierdo	CUMPLE	Eje4 Rin Derecho	CUMPLE	Eje4 Rin Izquierdo	CUMPLE
Eje5 Rin Derecho	CUMPLE	Eje5 Rin Izquierdo	CUMPLE	Latonería y Pintura	CUMPLE
Tapicería	CUMPLE	Cojinería	CUMPLE	Caja de Dirección	CUMPLE
Terminales	CUMPLE	Brazos Axiales	CUMPLE	Bastidor	CUMPLE
Pisos	CUMPLE	Promedio de Distancia	CUMPLE	Promedio de Tiempo	CUMPLE

RESULTADO : APROBADO

NOTAS Y RECOMENDACIONES DEL INSPECTOR DEL C.D.A.

(Espacio para notas sobre el estado del vehículo o para recomendaciones)

Frenos (Freno de estacionamiento (de parqueo de mano) con una eficacia inferior al 18 %.) TIPO B

LABRADO DE LAS RUEDAS (mm)		
Rueda De Repuesto		3,87
Izquierda		Derecha
Eje 1	3,25	3,48
Eje 2	3,98	3,64

the $\mathcal{O}(n^2)$ time complexity of the SVD algorithm. In addition, we can also use the SVD algorithm to find the principal components of the data matrix X . The principal components are the columns of the matrix U multiplied by the singular values σ_i . This is because the columns of U are orthogonal unit vectors, and the singular values σ_i are the square roots of the eigenvalues of $X^T X$. Therefore, the principal components are the eigenvectors of $X^T X$ scaled by their corresponding eigenvalues.

In conclusion, the SVD algorithm is a powerful tool for dimensionality reduction and feature extraction. It is widely used in machine learning and data analysis applications, such as recommendation systems, image processing, and natural language processing.

As a final note, it is important to remember that the SVD algorithm is not always the best choice for dimensionality reduction. There are other algorithms, such as PCA (Principal Component Analysis), that may be more appropriate depending on the specific characteristics of the data. However, the SVD algorithm is a well-known and effective method for finding the principal components of a data matrix.

In summary, the SVD algorithm is a powerful tool for dimensionality reduction and feature extraction. It is based on the decomposition of a data matrix into three matrices: U , S , and V . The matrix U contains the principal components of the data, while the matrix S contains the singular values. The matrix V contains the right singular vectors. The SVD algorithm has a time complexity of $\mathcal{O}(n^2)$, which makes it less efficient than some other dimensionality reduction methods. However, it is a well-known and effective method for finding the principal components of a data matrix.

As a final note, it is important to remember that the SVD algorithm is not always the best choice for dimensionality reduction. There are other algorithms, such as PCA (Principal Component Analysis), that may be more appropriate depending on the specific characteristics of the data. However, the SVD algorithm is a well-known and effective method for finding the principal components of a data matrix.

In conclusion, the SVD algorithm is a powerful tool for dimensionality reduction and feature extraction. It is based on the decomposition of a data matrix into three matrices: U , S , and V . The matrix U contains the principal components of the data, while the matrix S contains the singular values. The matrix V contains the right singular vectors. The SVD algorithm has a time complexity of $\mathcal{O}(n^2)$, which makes it less efficient than some other dimensionality reduction methods. However, it is a well-known and effective method for finding the principal components of a data matrix.