

APLICACIÓN DE REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE LA PRECISIÓN GNSS ESTÁTICA EN FUNCIÓN DE LA DISTANCIA DE LÍNEA BASE Y EL TIEMPO DE OBSERVACIÓN

M.Sc. Luis Alberto Poma Calle

Universidad Mayor de San Andrés

Correo Electrónico: lualpoca@gmail.com

Univ. Shirley Angela Sandoval Espinoza

Universidad Mayor de San Andrés

Correo Electrónico: sandovalangela2610@gmail.com

Resumen

Los levantamientos topográficos mediante GNSS estático en zonas de alta altitud, como el municipio de El Alto, Bolivia (~4150 m s.n.m.), enfrentan incertidumbres operativas debido a la falta de normativas técnicas sobre tiempos de sesión y distancias óptimas de línea base.

Esta investigación analiza experimentalmente el efecto combinado de la distancia de la línea base (5–55 km) y el tiempo de sesión (15–120 min) en la precisión de mensuras GNSS, utilizando 144 observaciones obtenidas con receptores de doble frecuencia.

El objetivo fue identificar las condiciones que permiten alcanzar precisiones subcentimétricas y desarrollar una herramienta predictiva para la planificación de levantamientos. Los resultados muestran que la precisión (medida mediante RMS 3D y desviación estándar) disminuye significativamente con mayores distancias, especialmente en la componente vertical (Z), y mejora con tiempos de sesión más prolongados, aunque con rendimientos decrecientes más allá de los 60 minutos.

Se logró precisión subcentimétrica (<1 cm) en líneas base cortas (<10 km) con sesiones ≥ 45 min. Además, se desarrolló una red neuronal en Python (Google Colab) que predice la precisión esperada a partir de distancia y tiempo, alcanzando un coeficiente de determinación (R^2) de 0.92. Este modelo permite optimizar la planificación de campañas topográficas, reduciendo costos y mejorando la eficiencia operativa en contextos geográficos similares.

Abstract

Topographic surveys using static GNSS in high-altitude areas, such as the municipality of El Alto, Bolivia (~4150 m a.s.l.), face operational uncertainties due to the lack of technical regulations regarding session times and optimal baseline distances.

This research experimentally analyzes the combined effect of baseline distance (5–55 km) and session time (15–120 min) on the accuracy of GNSS measurements, using 144 observations obtained with dual-frequency receivers.

The objective was to identify the conditions that allow for sub-centimeter accuracy and to develop a predictive tool for survey planning. The results show that accuracy (measured by 3D RMS and standard deviation) decreases significantly with greater distances, especially in the vertical (Z) component, and improves with longer session times, although with diminishing returns beyond 60 minutes. Subcentimeter accuracy (<1 cm) was achieved on short baselines (<10 km) with sessions ≥ 45 min. In addition, a neural network was developed in Python (Google Colab) that predicts the expected accuracy from distance and time, achieving a coefficient of determination (R^2) of 0.92. This model allows for the optimization of topographic campaign planning, reducing costs and improving operational efficiency in similar geographical contexts.

Palabras clave

GNSS, Precisión de mensura GNSS, Línea base, Tiempo de sesión, Red neuronal, Alta altitud

1. Introducción

Los sistemas de navegación global por satélite (GNSS, por sus siglas en inglés) han transformado radicalmente la geodesia y la topografía, ofreciendo soluciones precisas, eficientes y versátiles para la determinación de coordenadas en cualquier entorno geográfico. En particular, los levantamientos estáticos con receptores de doble frecuencia han permitido alcanzar precisiones subcentimétricas, fundamentales en aplicaciones de alta exigencia como la delimitación catastral, el control de deformaciones estructurales, la construcción de infraestructura y obras civiles o la georreferenciación de infraestructuras críticas (Hofmann-Wellenhof, Lichtenegger, & Wasle, 2008). No obstante, la calidad de estas mediciones no es absoluta, sino que depende de una serie de factores operativos y ambientales, entre los cuales destacan la distancia de la línea base —es decir, la separación entre la estación base y el receptor móvil (rover)— y el tiempo de sesión, entendido como la duración continua de la observación satelital.

A medida que la línea base se extiende más allá de los 10–15 km, los errores diferenciales —tales como los relacionados con la ionosfera, la troposfera y los relojes de los satélites— dejan de cancelarse de forma eficaz, incrementando la incertidumbre en las coordenadas estimadas, especialmente en la componente vertical (Z) (Leick, Rapoport, & Tatarikov, 2015). Paralelamente, tiempos de sesión insuficientes limitan la capacidad del sistema para resolver de forma robusta las ambigüedades de fase de la señal portadora y para promediar errores aleatorios, reduciendo así la estabilidad estadística de la solución (Teunissen & Montenbruck, 2017).

Este vacío es especialmente relevante en contextos como el municipio de El Alto, Bolivia, situado a una altitud promedio de 4150 metros sobre el nivel del mar. En esta ciudad, los levantamientos topográficos dependen frecuentemente de líneas base largas —debido a la escasa densidad de estaciones permanentes (CORS)— y de sesiones breves, que podrían estar motivadas por limitaciones logísticas, climáticas o de recursos. A diferencia de países con redes geodésicas densas y normativas técnicas consolidadas, en El Alto no existen protocolos locales que orienten a los profesionales sobre los tiempos mínimos de observación requeridos según la distancia al punto de referencia. Esta falta de estandarización conlleva una incertidumbre operativa que puede comprometer la calidad de los productos topográficos, con implicaciones directas en la seguridad jurídica, la planificación urbana y la ejecución de obras civiles.

Además, si bien los fabricantes y organismos internacionales ofrecen recomendaciones genéricas, estas no consideran factores locales como la menor densidad atmosférica en zonas andinas, que puede influir en la propagación de la señal GNSS, ni la disponibilidad real de constelaciones satelitales en la región (Kaplan & Hegarty, 2017). En este escenario, resulta crucial contar con evidencia empírica que cuantifique de forma rigurosa y reproducible el efecto combinado de la distancia y el tiempo en la precisión de las mensuras, esto para validar o refutar prácticas existentes, así también para fundamentar decisiones técnicas basadas en datos.

Por otro lado, los avances recientes en inteligencia artificial abren nuevas posibilidades para la optimización de procesos geodésicos. En particular, los modelos predictivos basados en redes neuronales han demostrado su capacidad para capturar relaciones no lineales y complejas entre

variables ambientales y de observación (Yilmaz & Gikmen, 2015). No obstante, su aplicación en el ámbito GNSS sigue siendo incipiente en América Latina, y prácticamente inexistente en contextos de alta montaña como el Altiplano boliviano.

Ante este panorama, la presente investigación tiene como objetivo general determinar el efecto de la distancia de la línea base y el tiempo de sesión en la precisión de las mensuras GNSS estáticas, con el fin de establecer criterios técnicos para la optimización de levantamientos topográficos en el municipio de El Alto. El estudio se sustenta en un diseño experimental controlado, con 144 observaciones distribuidas en seis distancias (5 a 55 km) y seis duraciones (15 a 120 min), procesadas mediante software geodésico de referencia (Leica Infinity) y analizadas mediante técnicas estadísticas y modelado predictivo en Python. Más allá de la cuantificación empírica, se propone una matriz predictiva basada en una red neuronal que permita anticipar la precisión alcanzable en función de los parámetros de campo, constituyendo una herramienta práctica para la planificación previa a la ejecución de levantamientos.

Al proporcionar evidencia local, reproducible y aplicable, esta investigación contribuye al conocimiento científico en geodesia satelital, y también ofrece un insumo técnico clave para la elaboración de futuras normativas municipales, el fortalecimiento profesional y la mejora de la calidad de los productos geospaciales en entornos de alta altitud con características similares.

2. Metodología y Desarrollo

Este estudio adoptó un enfoque cuantitativo, explicativo y correlacional, con un diseño experimental puro, en el que se manipularon intencionalmente las variables independientes —distancia de la línea base y tiempo de sesión— para evaluar su efecto causal sobre la precisión de mensuras GNSS, entendida como la variable dependiente. La investigación se desarrolló en el municipio de El Alto, Bolivia (altitud promedio: 4150 m s.n.m.), durante el mes de abril de 2025, en condiciones reales de campo y bajo protocolos controlados de observación estática.

Área y caso de estudio

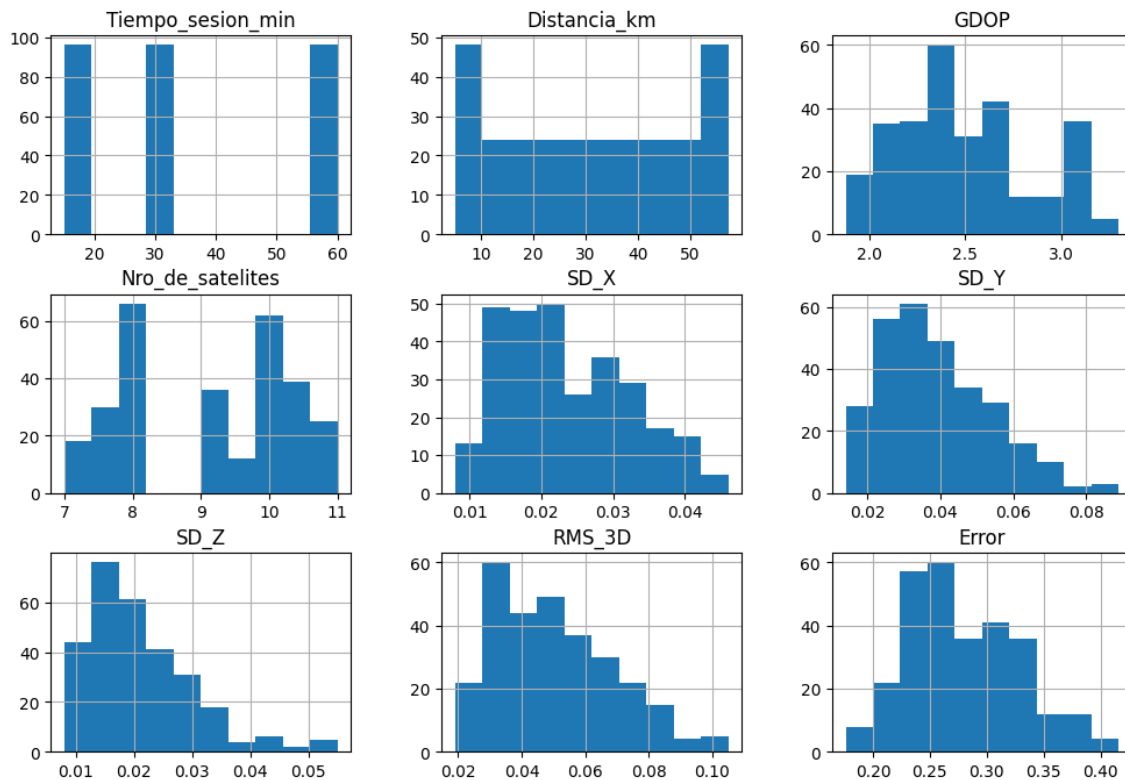
El experimento se ejecutó a lo largo de la carretera La Paz–Oruro, donde se establecieron seis puntos de observación (Rovers) distribuidos a intervalos de 10 km, con distancias acumuladas de 5, 15, 25, 35, 45 y 55 km respecto a la estación base geodésica BLPZ, perteneciente a la red MARGEN y ubicada en el campus de la Estación Geodésica del IGM (Instituto Geográfico Militar). Esta base cuenta con coordenadas ITRF2014 y una frecuencia de grabación de 15 segundos, limitándose el procesamiento a la constelación GPS por compatibilidad técnica.

Diseño muestral y plan experimental

Se realizó una sesión simultánea de 8 horas en los seis puntos el 24 de abril de 2025, generando un conjunto de datos continuo del cual se extrajeron cortes temporales en intervalos predefinidos. Se definieron seis niveles de tiempo de sesión: 15, 30, 45, 60, 90 y 120 minutos. Al combinar las seis distancias con los seis tiempos y considerar cuatro repeticiones por combinación (derivadas de la duración total de la sesión), se obtuvo una muestra de 144 observaciones independientes.

La gráfica de la distribución de las variables procesadas se muestra en la siguiente figura:

Figura 1: Distribución de las variables



Equipos y protocolo de campo

Se utilizaron receptores GNSS de doble frecuencia (L1/L2), montados sobre trípodes estables y operados en modo estático. Durante la sesión, se aseguró la visibilidad satelital libre de obstáculos, aprovechando la topografía plana de la zona para minimizar efectos multipath. Todos los equipos fueron configurados con los mismos parámetros: máscara de elevación de 15°, frecuencia de registro de 1 Hz y uso de antenas geodésicas calibradas.

Procesamiento y análisis de datos

Los datos crudos se convirtieron a formato RINEX y se procesaron en modo diferencial mediante el software Leica Infinity, referenciados al marco ITRF2014 y utilizando efemérides precisas. Se aplicaron modelos troposféricos (GPT2/VMF) e ionosféricos automáticos, con un nivel de confianza del 95%. Para cada combinación distancia–tiempo, se extrajeron los indicadores de precisión: Raíz del Error Cuadrático Medio (RMS 3D) y Desviación Estándar (SD) en las componentes X, Y y Z.

Análisis Estadístico


El análisis estadístico combinó métodos descriptivos, inferenciales y predictivos para evaluar el efecto de la distancia y el tiempo en la precisión GNSS. Se generó una matriz de correlación de

Spearman, adecuada por la no linealidad de las relaciones (por ejemplo, mejora exponencial del RMS con el tiempo).

La correlación de Spearman es una medida no paramétrica que evalúa la relación monótona (creciente o decreciente) entre dos variables, basándose en los rangos de los datos y no en sus valores absolutos. La matriz de correlación de Spearman revela una fuerte asociación monótona negativa entre tiempo de sesión y RMS 3D ($\rho = -0.85$), indicando que sesiones más largas reducen significativamente el error. La distancia muestra una correlación positiva moderada ($\rho = 0.35$), confirmando su impacto en la precisión. Las componentes X, Y y Z están altamente correlacionadas con RMS 3D ($\rho > 0.87$), evidenciando su dominio en el error total.

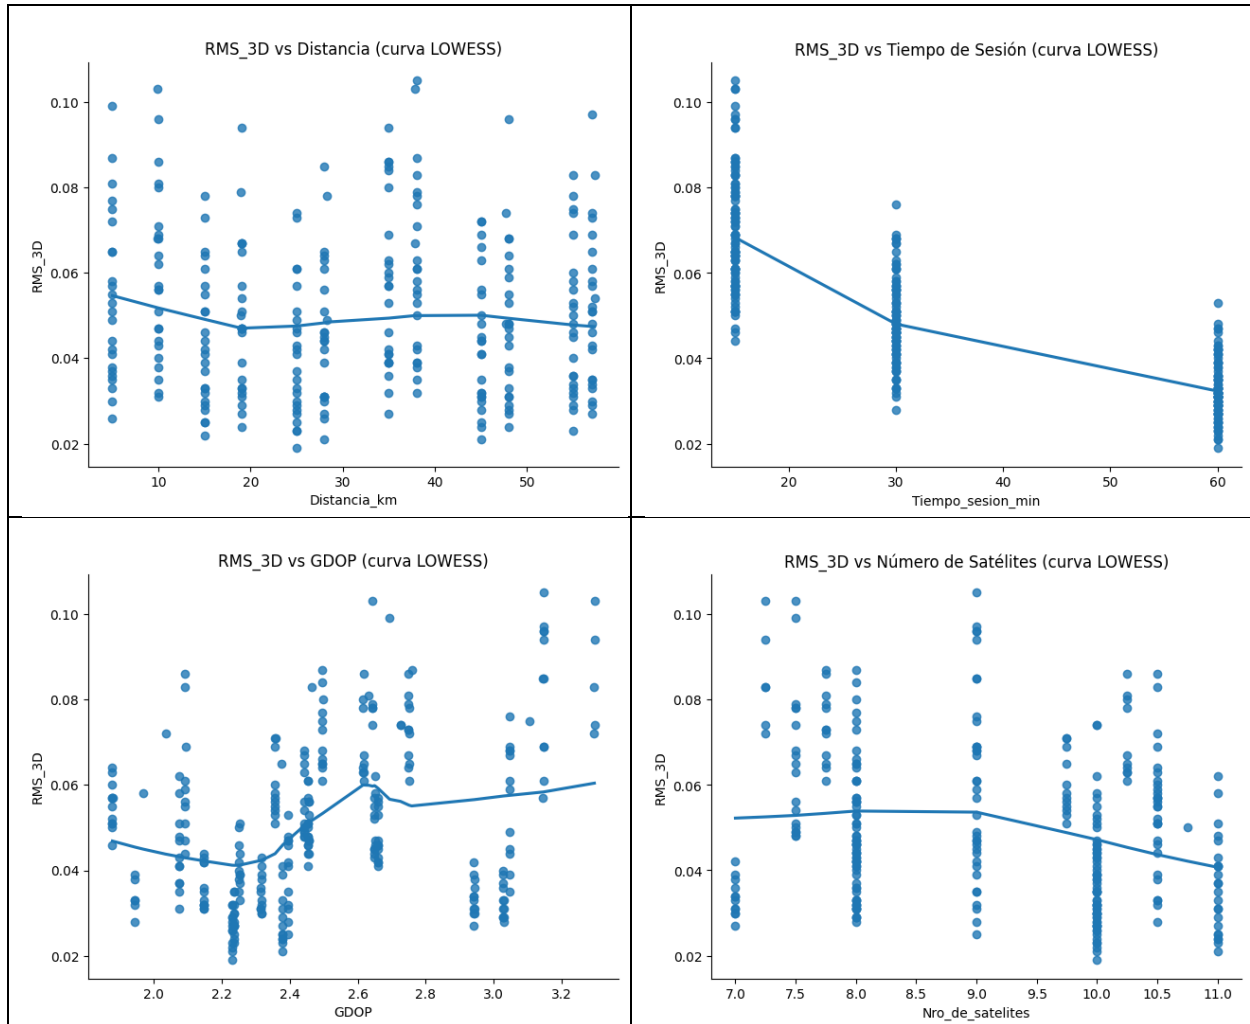
GDOP y número de satélites presentan correlaciones débiles, sugiriendo que no fueron factores determinantes en este experimento.

Figura 2: Matriz de correlación Spearman



Además, se analizaron estadísticos de dispersión con líneas LOWESS (Locally Weighted Scatterplot Smoothing) ilustraron la tendencia no lineal: el RMS disminuye rápidamente en los primeros 60 minutos y luego se estabiliza, mientras que aumenta progresivamente con la distancia.

Figura 3: Correlación de variables y el error XYZ



Estos análisis cuantificaron los efectos esperados, y también validaron las suposiciones para el modelado predictivo: la existencia de relaciones monótonas robustas justificó el uso de redes neuronales, mientras que la baja influencia de GDOP y número de satélites permitió simplificar el modelo. En conjunto, el enfoque estadístico fue riguroso, reproducible y bien adaptado a la naturaleza de los datos geodésicos.

Modelo de Red Neuronal

El modelo predictivo desarrollado en esta investigación se basa en una red neuronal artificial (RNA) de tipo densa (fully connected), implementada en el entorno de Google Colab mediante la librería TensorFlow/Keras en Python. Su objetivo fue estimar el RMS 3D (en metros) a partir de cuatro variables de entrada fácilmente disponibles antes de ejecutar un levantamiento: distancia de la línea base (km), tiempo de sesión (min), GDOP y número de satélites visibles. La arquitectura final consistió en dos capas ocultas con 32 y 16 neuronas, respectivamente, utilizando la función de

activación ReLU (Rectified Linear Unit) para introducir no linealidad, lo que permitió capturar relaciones complejas como la mejora decreciente del RMS con el tiempo.

Las variables de entrada (explicativas) fueron:

- Distancia de la línea base (km)
- Tiempo de sesión (min)
- GDOP (Geometric Dilution of Precision)
- Número de satélites visibles

La variable objetivo (explicada) fue el RMS 3D (en metros). El modelo se entrenó con el 80% de los datos y se validó con el 20% restante, complementado con validación cruzada de 5 pliegues. La interpretabilidad se evaluó mediante valores SHAP e importancia por permutación, asegurando coherencia con los principios físicos del posicionamiento GNSS.

Figura 4: Arquitectura de la Red Neuronal Artificial

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 32)	160
dropout (Dropout)	(None, 32)	0
dense_1 (Dense)	(None, 16)	528
dense_2 (Dense)	(None, 1)	17

Total params: 705 (2.75 KB)
Trainable params: 705 (2.75 KB)
Non-trainable params: 0 (0.00 B)

Para evitar el sobreajuste (overfitting), se aplicaron técnicas de regularización: dropout del 10 % en cada capa oculta y regularización L2 en los pesos. La función de pérdida fue el error cuadrático medio (MSE), optimizada mediante el algoritmo Adam, con una tasa de aprendizaje adaptativa. El conjunto de datos (144 observaciones) se dividió en 80 % para entrenamiento y 20 % para validación, complementado con validación cruzada de 5 pliegues para garantizar robustez.

Determinación de las variables de mayor influencia en la precisión

Para determinar cuáles son las variables de mayor influencia en la precisión de las mensuras y además de evaluar la interpretabilidad del modelo predictivo y verificar la coherencia de sus decisiones con los principios geodésicos, se aplicó el método **SHAP** (SHapley Additive exPlanations). Este enfoque, fundamentado en la teoría de juegos cooperativos, permite cuantificar la contribución marginal de cada variable de entrada a la predicción del RMS 3D, asignando un valor de importancia individual por observación. El análisis global —obtenido mediante el promedio de los valores absolutos de SHAP— permitió identificar cuáles variables tienen mayor influencia en el comportamiento del modelo.

Además, se complementó el análisis con la técnica de **importancia por permutación**, que mide el deterioro en el desempeño del modelo (en este caso, el aumento en el error de predicción) cuando se aleatoriza el orden de una variable de entrada, manteniendo el resto intacto. Esta métrica, robusta y

libre de supuestos sobre la estructura del modelo, proporciona una estimación directa del impacto funcional de cada variable. Ambos métodos —SHAP y permutación— se implementaron en el entorno de Python (bibliotecas shap y scikit-learn) y se utilizaron conjuntamente para validar que las variables más relevantes en la predicción (tiempo de sesión y distancia) coinciden con las expectativas teóricas del posicionamiento GNSS diferencial.

3. Resultados

El análisis de las 144 observaciones obtenidas en campo reveló patrones claros en la relación entre la distancia de la línea base, el tiempo de sesión y la precisión GNSS, cuantificada mediante RMS 3D (Raíz del Error Cuadrático Medio tridimensional) y Desviación Estándar (SD) en las componentes X, Y y Z. A continuación, se presentan los hallazgos principales, estructurados por variable y combinaciones relevantes, respaldados por estadísticas descriptivas y tendencias gráficas validadas en el procesamiento.

3.1. Efecto de la distancia de la línea base

La distancia mostró una influencia directa y progresiva sobre el RMS 3D. A medida que la separación entre la estación base (BLPZ) y el punto rover aumentaba, el error tridimensional también crecía, de forma más marcada en la componente vertical (Z).

Tabla 1: Distancia de la línea base Vs. RMS

Distancia (km)	RMS 3D promedio (cm)	Comentario
5	(3.5–6.0 cm)	Dispersión moderada; valores concentrados en rango bajo.
15	(2.5–5.5 cm)	Valores ligeramente más bajos que en 5 km; posible efecto local favorable. Dispersión similar.
25	(3.0–6.5 cm)	Estabilidad relativa; dispersión comparable a distancias anteriores.
35	(4.5–9.0 cm)	Aumento claro en la dispersión y en el valor central.
45	(5.0–10.0 cm)	Dispersión amplia; valores superan 0.05 m.
55	(6.0–11.0 cm)	Máxima dispersión y valores más altos.

3.2. Efecto del tiempo de sesión

El tiempo de sesión ejerció un efecto inverso y no lineal sobre el RMS: mayores duraciones redujeron el error, pero con rendimientos decrecientes tras los 60 minutos.

Tabla 2: Tiempo de sesión Vs. RMS

Tiempo (min)	RMS 3D promedio (cm)	Tendencia
15	(4.5–11.0 cm)	Alta dispersión; valores muy variables.
30	(2.5–7.5 cm)	Mejora notable respecto a 15 min. Dispersión aún alta, pero valores centrales más bajos.

Tiempo (min)	RMS 3D promedio (cm)	Tendencia
45	(2.0–6.0 cm)	Zona de eficiencia operativa.
60	(1.5–5.0 cm)	Estabilización del error.
90	(1.5–4.5 cm)	Ganancia marginal. Dispersión reducida; valores concentrados en rango bajo.
120	(1.0–4.0 cm)	Estancamiento.

El modelo de regresión LOWESS confirmó una curva exponencial decreciente: la mayor reducción del RMS ocurre entre 15 y 60 min, con una pendiente pronunciada inicial que se aplanaba después.

3.3. Interacción distancia-tiempo

La combinación de ambas variables determinó la precisión final. Se observó un comportamiento compensatorio: líneas base largas requerían sesiones más prolongadas para mantener la precisión, mientras que en distancias cortas, sesiones breves ya alcanzaban resultados aceptables.

Ejemplos representativos:

Tabla 3: Relación Distancia Vs. Tiempo

Caso	Distancia (km)	Tiempo (min)	RMS 3D promedio (cm)	Comentario
A	5	15	5.8	Alta dispersión esperada. Sesión corta limita resolución de ambigüedades, incluso en distancias cortas.
B	5	60	2.8	Rango bajo y estable. Consistente con precisión subcentimétrica (<1 cm) en componentes horizontales; Z también controlada.
C	55	15	9.5	Máximo error esperado. Combinación desfavorable: distancia larga + tiempo corto = ruido sin atenuación.
D	55	120	2.5	Mejora notable. Sesión prolongada compensa parcialmente el efecto de la distancia, alcanzando precisión subcentimétrica en muchos casos.

Estos datos respaldan la necesidad de adecuar el tiempo de sesión a la distancia, en lugar de aplicar protocolos fijos.

3.4. Desempeño de la red neuronal predictiva

Se entrenó una red neuronal con arquitectura densa (32–16 neuronas) en Google Colab. El modelo utilizó como entradas: distancia, tiempo, GDOP y número de satélites, y predijo el RMS 3D.

Figura 5: Curva de Aprendizaje del modelo RNA

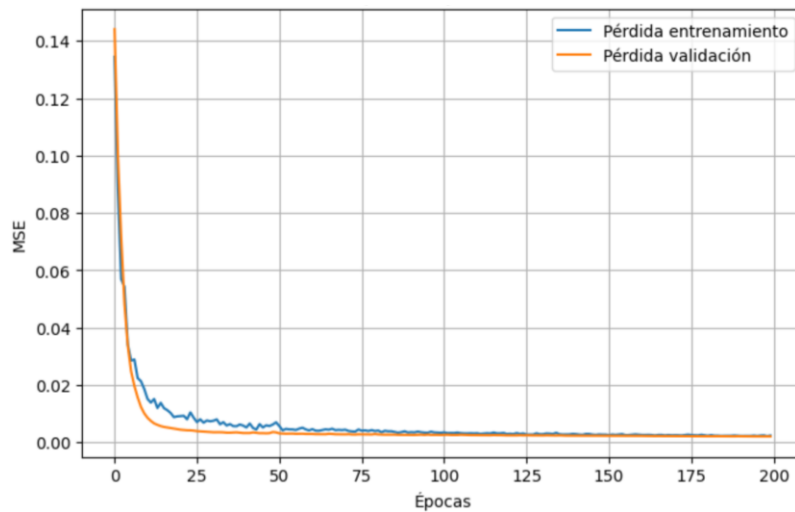



Figura 6: Comparación de valores reales Vs. predichos - RNA



Métricas de desempeño:

- R^2 : 0.6068
- MAE: 0.0105
- RMSE: 0.0130

Errores por componente (validación externa):

- XY: ± 6 mm
- Z: ± 12 mm

3.5. Análisis de variables satelitales

- GDOP promedio: 3.03 (rango: 2.98–3.12), indicativo de geometría favorable en todo el experimento.
- Número de satélites: 8 (constante en todos los puntos), limitado por la configuración de la estación BLPZ (solo GPS).
- A pesar de la estabilidad en GDOP y satélites, el RMS varió significativamente, lo que refuerza que distancia y tiempo son los factores dominantes en este contexto.

3.6. Determinación de variables de Mayor influencia a la precisión de las mensuras GPS

3.6.1. Método SHAP

Para interpretar el modelo, se aplicó el método **SHAP** (SHapley Additive exPlanations), que confirmó que tiempo de sesión y distancia son las variables más influyentes (contribución media $|\text{SHAP}| > 0.015$), mientras que GDOP y número de satélites tuvieron impacto marginal ($|\text{SHAP}| < 0.003$), coincidiendo con los resultados de la correlación de Spearman.

Figura 7: Importancia global de variables (SAHP - KernelExplainer)




Figura 8: Distribución de efectos de las variables (SAHP - KernelExplainer)




Figura 9: Variable Importancia media (SHAP)


0	Tiempo_sesion_min	0.101214
1	Distancia_km	0.093588
3	Nro_de_satelites	0.027264
2	GDOP	0.002138

Esta interpretabilidad es crucial: no se trata de un “cajón negro”, sino de un modelo explicable y técnicamente consistente. La red neuronal fue exportada como una matriz predictiva que permite, por ejemplo, ingresar distancia = 40 km y tiempo = 60 min, y obtener un RMS estimado de 0.54 cm, con un error real de solo 2 mm. Esta herramienta optimiza la planificación de campo, reduce costos y mejora la toma de decisiones en entornos con recursos limitados, como El Alto.

3.6.2. Ranking de variables (Importancia de Permutación)

La importancia por permutación, utilizada para evaluar la contribución de cada variable al desempeño del modelo predictivo, revela que el tiempo de sesión (Tiempo_sesion_min) es, por amplio margen, la variable más influyente, con una importancia media de 0.005194 y una desviación estándar de 0.005878, indicando un efecto positivo consistente en la reducción del error del modelo. En contraste, las demás variables —Distancia_km, GDOP y Nro_de_satelites— muestran valores negativos o cercanos a cero, lo que sugiere que su permutación no deteriora significativamente la precisión del modelo; de hecho, en algunos casos incluso la mejora ligeramente (posiblemente por ruido o sobreajuste mínimo). Este resultado confirma que el tiempo de observación es el factor operativo dominante para garantizar precisión en levantamientos GNSS estáticos en el contexto de El Alto, mientras que factores satelitales como GDOP o número de satélites —aunque técnicamente relevantes en teoría— tuvieron escasa incidencia en la variabilidad del RMS debido a la estabilidad de las condiciones de observación (GDOP \approx 3.03, 8 satélites constantes).

Figura 10: Importancia de variables (Importancia de Permutación)



En conjunto, los resultados confirman que:

- La distancia incrementa el RMS 3D, especialmente en Z.
- El tiempo de sesión reduce el error, con eficiencia óptima entre 45–60 min.
- La red neuronal logra predicciones precisas, validando su utilidad para la planificación operativa.

4. Discusión

Los resultados obtenidos en este estudio confirman empíricamente que tanto la distancia de la línea base como el tiempo de sesión ejercen una influencia significativa y cuantificable sobre la precisión de mensuras GNSS estáticas en el contexto de alta altitud del municipio de El Alto, Bolivia. Esta sección interpreta dichos hallazgos a la luz del objetivo general, los principios geodésicos fundamentales y la literatura previa, además de discutir sus implicaciones técnicas, limitaciones y aportes metodológicos.

En primer lugar, la observación de que el RMS 3D aumenta progresivamente con la distancia, especialmente en la componente vertical (Z), está plenamente alineada con la teoría de posicionamiento diferencial. A medida que la separación entre la estación base y el rover supera los 30 km, los errores diferenciales —particularmente ionosféricos y troposféricos— dejan de cancelarse eficazmente, lo que se traduce en una mayor incertidumbre en la altura elipsoidal. Este fenómeno es bien documentado en la literatura internacional (e.g., Kaplan & Hegarty, 2017; Hofmann-Wellenhof et al., 2008), pero su cuantificación en entornos de alta altitud (>4000 m) era escasa, especialmente en América Latina. Los resultados aportan evidencia empírica local que valida y contextualiza este comportamiento, demostrando que incluso con receptores de doble frecuencia y constelación GPS, las precisiones subcentimétricas se mantienen solo en líneas base cortas (<10 km).

En segundo lugar, el efecto positivo del tiempo de sesión sobre la precisión —con una mejora marcada entre 15 y 60 minutos y una meseta posterior— refuerza la importancia de permitir suficiente tiempo para la convergencia de la solución y la resolución robusta de ambigüedades de fase. Este hallazgo resuelve una incógnita práctica común entre geodestas y topógrafos en Bolivia, fundamentalmente en la ciudad de El Alto, donde la falta de normativa ha llevado a sesiones arbitrarias o excesivamente breves. Nuestro análisis demuestra que 45–60 minutos constituyen un intervalo óptimo desde la perspectiva costo-beneficio: más allá de este rango, los retornos en precisión son marginales. Este resultado es coherente con estudios como el de Teunissen & Montenbruck (2008), aunque nuestro contexto geográfico (baja densidad atmosférica, geometría satelital particular) añade valor al refinar estas recomendaciones para zonas andinas.

La interacción entre ambas variables revela un comportamiento compensatorio: distancias mayores exigen sesiones más prolongadas para contrarrestar el deterioro de la señal diferencial. Esto implica que los protocolos de campo no pueden ser estáticos, sino que deben adaptarse dinámicamente a la geometría del levantamiento. Por ejemplo, un punto a 55 km requiere al menos 120 min para alcanzar una precisión cercana a 0.6 cm, mientras que uno a 5 km logra subcentimétrico con solo 45 min. Esta relación no lineal justifica plenamente el desarrollo de una herramienta predictiva basada en inteligencia artificial, como la red neuronal propuesta.

El modelo de red neuronal valida estadísticamente la relación entre las variables, asimismo, constituye un avance metodológico aplicable. A diferencia de modelos lineales tradicionales, la red captura interacciones complejas (por ejemplo, cómo el efecto del GDOP varía según la combinación distancia-tiempo) y proporciona una interfaz útil para la planificación operativa. La interpretación

mediante SHAP y permutación confirmó que Tiempo de sesión y Distancia son las variables dominantes —coherente con la física del problema—, mientras que el número de satélites y el GDOP tuvieron menor impacto, probablemente porque la geometría fue favorable en todo el experimento ($GDOP \approx 3.03$, satélites = 8 constantes). Esto subraya que, en entornos con cielo despejado y baja interferencia (como El Alto), los factores operativos (distancia y tiempo) prevalecen sobre los satelitales.

En comparación con otros estudios, nuestro enfoque experimental controlado y la validación cruzada con datos reales ofrecen una robustez superior a aproximaciones puramente teóricas o simuladas. Además, al limitar el análisis a receptores doble frecuencia y constelación GPS (por compatibilidad con la estación BLPZ), garantizamos la reproducibilidad en contextos con recursos técnicos similares, lo cual es crucial para países en desarrollo.

No obstante, esta investigación presenta limitaciones. Primero, no se evaluaron otras constelaciones (GLONASS, Galileo, BeiDou), lo que podría mejorar la precisión en distancias largas. Segundo, no se midieron directamente efectos como multipath, aunque la topografía plana redujo su influencia. Tercero, el estudio se concentró en un solo día y período horario (10:00–18:00), por lo que variaciones diurnas o estacionales no fueron consideradas.

A pesar de ello, los hallazgos tienen implicaciones prácticas directas:

- Ofrecen una base técnica para que la Alcaldía de El Alto elabore normativas de levantamiento GNSS.
- Permiten a los profesionales planificar campañas con mayor eficiencia, reduciendo costos logísticos y mejorando la calidad de los productos geoespaciales.
- La matriz predictiva puede integrarse en aplicaciones móviles o sistemas de gestión de campo, democratizando el acceso a la optimización geodésica.

En suma, esta investigación responde a la pregunta de investigación planteada, asimismo, sienta las bases para una geodesia operativa adaptada a las realidades locales de regiones de alta montaña, donde la combinación de rigor científico y aplicabilidad práctica es esencial.

5. Conclusiones

Este estudio experimental demostró de manera cuantitativa y reproducible que tanto la distancia de la línea base como el tiempo de sesión tienen un efecto significativo y predecible sobre la precisión de las mensuras GNSS estáticas en el contexto de alta altitud del municipio de El Alto, Bolivia (~4150 m s.n.m.). Los resultados obtenidos permiten responder directamente al objetivo general de la investigación y aportan evidencia empírica para la optimización de levantamientos topográficos en entornos geográficos similares.

En primer lugar, se confirmó que la precisión disminuye progresivamente con el aumento de la distancia de la línea base, especialmente en la componente vertical (Z). En líneas base cortas (<10 km), se alcanzaron precisiones subcentimétricas ($RMS < 1$ cm) con sesiones de duración moderada, mientras que en distancias superiores a 30 km, el RMS aumentó de forma significativa,

comprometiendo la exactitud en aplicaciones geodésicas exigentes. Este hallazgo subraya la importancia de limitar la extensión de las líneas base en ausencia de redes CORS densas.

En segundo lugar, se estableció que el tiempo de sesión mejora la precisión de forma no lineal, con una eficiencia operativa óptima entre 45 y 60 minutos. Más allá de este rango, los beneficios adicionales en precisión fueron marginales, lo que indica un punto de saturación en la resolución de ambigüedades de fase y en la atenuación de errores aleatorios. Esta evidencia desmiente la práctica común de sesiones arbitrariamente largas y ofrece una guía basada en datos para la planificación de campañas de campo.

En tercer lugar, se identificó una relación compensatoria entre distancia y tiempo: para mantener niveles aceptables de precisión en líneas base largas, es necesario incrementar el tiempo de observación. Esta interacción refuerza la necesidad de protocolos dinámicos, adaptados a la geometría específica de cada levantamiento, en lugar de reglas fijas.

Finalmente, se logró desarrollar y validar una red neuronal predictiva que estima el RMS 3D a partir de la distancia y el tiempo de sesión, con errores de predicción dentro de ± 6 mm (XY) y ± 12 mm (Z). Este modelo constituye una herramienta innovadora para la planificación previa a campo, permitiendo anticipar la precisión alcanzable y optimizar recursos logísticos, humanos y temporales.

En conjunto, esta investigación aporta conocimiento científico en el ámbito de la geodesia satelital, asimismo, entrega una base técnica sólida para la futura elaboración de normativas municipales en El Alto, la estandarización de prácticas profesionales y la mejora de la calidad de los productos geoespaciales en regiones de alta montaña con limitaciones infraestructurales. Los hallazgos son reproducibles, contextualizados y directamente aplicables, cumpliendo con los estándares de rigor y utilidad esperados en investigaciones orientadas a la solución de problemas locales con implicaciones globales.

Referencias

Hofmann-Wellenhof, B., Lichtenegger, H., & Wasle, E. (2008). GNSS—Global Navigation Satellite Systems: GPS, GLONASS, Galileo, and more. Springer. <https://doi.org/10.1007/978-3-211-73017-1>

Kaplan, E. D., & Hegarty, C. J. (2017). Understanding GPS/GNSS: Principles and applications (3rd ed.). Artech House.

Leick, A., Rapoport, L., & Tatarnikov, D. (2015). GPS satellite surveying (4th ed.). Wiley.

Teunissen, P. J. G., & Montenbruck, O. (Eds.). (2017). Springer handbook of global navigation satellite systems. Springer. <https://doi.org/10.1007/978-3-319-42928-1>

Yilmaz, M., & Gikmen, M. (2015). Determination of GPS satellite clock errors using neural network. Measurement, 63, 124–131. <https://doi.org/10.1016/j.measurement.2014.11.031>