

Pronóstico Jerárquico con un Enfoque Multivariado

ESPINOSA-ARRIAGA Alejandro
alejandro.espinosa@uanl.edu.mx




La globalización ha ampliado las cadenas de suministro a nivel mundial, aumentando tanto el consumo como la complejidad de la distribución de productos y servicios. La eficiencia en este sistema complejo es crítica, requiriendo herramientas avanzadas para optimizar el uso de recursos y minimizar las pérdidas. Entre estas, los sistemas de predicción de demanda son fundamentales para evitar el exceso de inventario y las oportunidades de venta perdidas, ayudando a reducir costos significativamente. En el sector minorista, la precisión de estas predicciones en el nivel más detallado es vital debido a su impacto económico directo. Sin embargo, el análisis de pronóstico de demanda afronta el desafío de errores inherentes al no considerar las correlaciones entre los diferentes niveles jerárquicos, lo que hace esencial la implementación de técnicas de reconciliación de pronósticos (Bradlow, 2017), (Senge, 2022), (Hyndman, 2011).

Introducción

Metodología y materiales

Se utilizaron tablas de una base de datos SQL pertenecientes a un cliente de BlueYonder anonimizados por políticas de privacidad y confidencialidad. Las características y las ventas históricas se utilizaron para los modelos utilizados. El pronóstico del producto LDE se utilizaron como base para evaluar los resultados. Los modelos utilizados para evaluar el pronóstico base son XGBoost (Newbold, P., 1983), CNN (Albawi & et. al. 2017) y SARIMA (Newbold, P., 1983). La técnica de agregación a utilizar es la reconciliación jerárquica propuesta por Hyndman (2011).




Conjunto de datos histórico

Esta gráfica muestra las ventas agregadas para las combinaciones utilizadas en este trabajo. Se puede apreciar un comportamiento cíclico y temporal con algunos datos atípicos.

Formato de datos

Esta tabla muestra el formato y las características utilizadas. Las variables fueron codificadas y normalizadas para mejorar el entrenamiento de los modelos.

Date	P_ID	L_ID	Product Name	PG 1	PG 2	PG 3	PG 4	Latitude	Longitude	Region	Event Name	Event Type	Max Temperature	Min Temperature	Sales	Predictions
12/30/21	180578	2724	Plastic bucket 14L	GARDEN-b	0005045-c	47880	47877	51.365258	-2.171447	1	Wiltshire - Winter Holidays	school_holiday	13.25	11.79	3	6.051539
12/29/21	180578	2724	Plastic bucket 14L	GARDEN-b	0005045-c	47880	47877	51.365258	-2.171447	1	Wiltshire - Winter Holidays	school_holiday	13.89	6.83	1	6.799977
12/28/21	180578	2724	Plastic bucket 14L	GARDEN-b	0005045-c	47880	47877	51.365258	-2.171447	1	Wiltshire - Winter Holidays	school_holiday	9.78	7.19	1	6.872981
12/27/21	180578	2724	Plastic bucket 14L	GARDEN-b	0005045-c	47880	47877	51.365258	-2.171447	1	Wiltshire - Winter Holidays	school_holiday	10.17	5.74	0	8.481632
12/26/21	180578	2724	Plastic bucket 14L	GARDEN-b	0005045-c	47880	47877	51.365258	-2.171447	1	Wiltshire - Winter Holidays	school_holiday	9.87	5.13	0	0.520089



Modelo base: LDE

Se utilizan las predicciones generadas por el modelo LDE de BlueYonder como pronóstico base para comparar los modelos utilizados y la técnica de agregación por reconciliación de jerarquía.

Resultados

Los 3 modelos utilizados agregados por medio de suma, demostraron un error mayor al del 10% de error absoluto medio ponderado comparado con los resultados de LDE. El proceso de reconciliación de predicciones demostró, sin embargo, un incremento en las métricas agregadas a nivel total del modelo. Utilizando la técnica, se logró superar los resultados base en promedio por más del 3%.

Sin embargo, el proceso utilizado para corregir las predicciones a niveles superiores de jerarquía utiliza más recursos computacionales que se tienen que considerar al momento de realizar el pronóstico jerárquico.

Tabla de Resultados

WMAPE	LDE	XGBoost	XGBoost Rec	CNN	CNN Rec	SARIMA	SARIMA Rec
Total	0.904	1.11	0.86	1.21	0.89	1.33	1.15
PG1-Region	1.02	1.15	0.94	1.27	0.94	1.37	0.99
PG2-Region	1.01	1.14	0.94	1.25	0.96	1.35	0.98

Conclusiones

Se concluye que el uso de reconciliación de pronóstico jerárquico para series de tiempo de demanda en la industria de mercado minorista (retail) demuestra añadir un valor agregado al momento de describir el rendimiento de un modelo predictivo a niveles de agregación superiores al granular que se utilice (en este trabajo se utilizó un nivel de granularidad de producto-tienda-día).

Se recomienda en un trabajo futuro comparar los tiempos de ejecución de generar pronóstico de series de tiempo a distintos niveles jerárquicos comparado con calcular la reconciliación de las predicciones granulares.

Referencias

Bradlow, E. T. (2017). The role of big data and predictive analytics in retailing. *Journal of Retailing*, 93(1), 79-95.
 Senge, M. U. (2022). Classification-based model selection in retail demand forecasting. *International Journal of Forecasting*, 38 (1), 209-223. doi.org/10.1016/j.ijforecast.2021.05.010
 Hyndman, R. J., Ahmed, R. A., Athanasopoulos, G., & Shang, H. L. (2011). Optimal combination forecasts for hierarchical time series. *Computational Statistics & Data Analytics*, 2579-2589.
 Newbold, P. (1983) ARIMA model building and the time series analysis approach to forecasting. *Journal of Forecasting*, 2 (1), 23-25. doi.org/10.1002/for.3980020104
 S. Albawi, T. A. Mohammed & S. Al-Zawi (2017) Understanding of a convolutional neural network 2017 International Conference on Engineering and Technology (ICET), Antalya, Turkey, pp. 1-6, 10.1109/ICEngTechnol.2017.8308186.

