Financiado por la Unión Europea NextGenerationEU
Gobierno de España · Vicepresidencia Primera del Gobierno · Ministerio de Asuntos Económicos y Transformación Digital · Secretaría de Estado de Digitalización e Inteligencia Artificial
Plan de Recuperación, Transformación y Resiliencia
España | digital 2026
incibe_ Instituto Nacional de Ciberseguridad

Alicia Mayor Bal
presenta el resumen del trabajo

Artificial neural network models for airpot capacity prediction

Sun Choi, Young Jim kim
Journal of Air Transport Management 97 (2021) .
10 de julio de 2024

SERIE DE RESÚMENES EN ESPAÑOL

Palabras clave: Airport capacity prediction, Artificial Neural Networks, LSTM (Long Short-Term Memory), MLP (Multilayer perceptron), RNN (Recurrent Neural Networks).

Introducción

La capacidad de un aeropuerto viene determinada por la cantidad de llegadas y salidas realizadas durante períodos de alta demanda. Debido a situaciones meteorológicas o influencia proveniente de otros aeropuertos, esta capacidad suele verse sobrepasada, generando retrasos.

El campo de la predicción de capacidad permite ajustar las salidas y llegadas para reducir retrasos y minimizar el número de vuelos en espera. Sin embargo, la **capacidad de un aeropuerto es dificil de predecir** debido a contar con numerosos factores interconectados: los datos de capacidad tienen un patrón diario, es una medición no lineal y depende de la meteorología.

Este paper propone un modelo basado en redes neuronales artificiales para predecir la capacidad por horas de un aeropuerto, que es capaz de aprender funciones no lineales usando una estuctura multicapa.

1. Metodología

El rendimiento tanto de MLP (Perceptrón Multicapa), RNN (Red Neuronal Recurrente) como LSTM (Gran memoria a corto plazo) depende de la **construcción de sus capas**. La estructura de cada arquitectura es determinada mediante el método de búsqueda en rejilla, una técnica de ajuste para identificar la combinación óptima de hiperparámetros, que obtuvo como resultado la implementación de 2 capas ocultas para cada arquitectura.

En el **MLP** se proporciona para cada iteración un subset del set de entrenamiento proveniente de la capa de entrada. En este caso, la capacidad del aeropuerto para un momento dado y las caractertísticas meteorológicas en ese mismo instante constituyen una muestra. Tras las capas ocultas y la aplicacón de la función de la tangente hiperbólica, se obtiene el resultado en la capa de regresión lineal de salida.

En el caso de **RNN y LSTM**, se usa la secuencia de capacidad por hora del aeropuerto para k horas como entrada. Ambos modelos aplican un dropout con un 30 % de probabilidad y cuentan con una salida con regresión lineal.

Varias **combinaciones de capas** han sido probadas, pero no consiguen mejorar significativamente la estructura explicada con dos capas ocultas. Añadir más capas podría mejorar levemente la exactitud del modelo pero también implicaría un aumento en el cómputo.

Las **métricas** usadas para comparar el rendimiento de los modelos son la MSE (Error cuadrático) y la RMSE (Error de raíz cuadrada media).

2. Experimento

El estudio se lleva a cabo sobre el Aeropuerto Internacional Hartsfield-Jackson de Atlanta. Los datos extraídos son **preprocesados** previamente, cambiando las variables categóricas a numéricas, rellenando valores inexistentes con interpolación lineal y normalizando las variables.

Las **muestras de entrenamiento** vienen dadas por el par (x, y_t), siendo x las características (fecha, tiempo y meteorología en la terminal) e y_t un entero que representa la capacidad actual.

El sistema se construye apilando los bloques de construcción que forman cada uno de los tres modelos. Los parámetros de las redes son **inicializados** utilizando el algoritmo de Xavier (los pesos de la red se

seleccionan para ciertos valores intermedios); y los datos históricos y de meteorología son divididos en sets de entrenamiento y test, con un ratio de 9:1.

El set de entrenamiento es propagado, produciendo una salida y, a continuación se calcula la **función de pérdida** mediante la diferencia entre los valores actuales y los de salida del modelo. Si la condición de convergencia del modelo no se satisface, el valor del error es propagado hacia atrás en la red, actualizando así los parámetros del modelo y haciendo que las iteraciones continúen hasta que el modelo converja.

Los modelos son entrenados durante 300 épocas con un tamaño de lote de 200.

3. Resultados

Los tres modelos convergen de manera exitosa con valores relativamente bajos de **MSE**, sin mostrar signos de sobreajuste.

En cuanto a **RMSE**, todos los modelos consiguen valores bajos, lo cual es positivo. El modelo LSTM es el que obtiene los menores valores de RMSE de entrenamiento tanto para llegadas como para salidas (1.30 y 1.31 respectivamente). Se observa además, que los valores son mejores a modo general para las salidas tanto en RMSE de entrenamiento como de test, lo que indica que los modelos encuentran más fácil la extracción de información de salidas que de llegadas en base a los datos de entrada.

Tras la extracción de gráficas comparativas entre los valores actuales y predichos, se observa que LSTM y RNN muestran mayor rendimiento que MLP. **MLP subestima valores altos de capacidad**, a causa de la distribución de los datos sobre capacidad. Existen muy pocas muestran con valores por encima de 100, lo que dificulta las oportunidades de aprendizaje sobre este rango de valores. A pesar de esto, RNN y LSTM son capaces de predecir de forma acertada capacidades de todos los rangos.

En cuanto a la capacidad de los modelos para **predecir datos que nunca ha visto**, MLP muestra el mejor rendimiento a pesar de ser el menos complejo. MLP predice más de el 80 % de las muestras de capacidad de llegadas y salidas con un error relativo menor a 0.1.

4. Transfer learning

Una vez concluido el experimento principal, se quiere observar si el modelo es **capaz de funcionar para otros aeropuertos**. Esto entra dentro del campo de transfer learning, que consiste en reutilizar modelos pre-entrenados. Si es posible aplicar esto, podría incluso no ser necesario entrenar el modelo para cada aeropuerto, dando la posibilidad de generar modelos nuevos, sintonizando modelos ya existentes con una cantidad pequeña de datos.

Se selecciona el **Aeropuerto Internacional Logan de Boston** para reutilizar el modelo generado.

MLP es exluído del transfer learning ya que el rendimiento de predicción para el aeropuerto de Boston es excelente basándose en el entrenamiento con datos de Atlanta.

Sin embargo, los modelos LSTM y RNN originales predicen un valor casi duplicado de capacidad de llegadas. Una vez aplicado el transfer learning y después de 10 épocas usando los datos pertenecientes al aeropuerto de Boston, ambos modelos se ajustan de forma exitosa. **Los modelos ajustados superaron a los modelos entrenados desde cero**, convergiendo rápidamente a valores bajos de RMSE.

5. Discusión/Conclusiones

Los algoritmos de redes neuronales artificiales estudiados en este paper (MLP, RNN y LSTM) han conseguido predecir satisfactoriamente tanto los sets de entrenamiento como los de test, obteniendo valores bajos de las métricas de comparación de rendimiento MSE y RMSE, incluso para el modelo menos complejo, el MLP.

Un enfoque muy importante es la capacidad de transferibilidad que ha sido probada para los modelos con el aeropuerto de Boston, generando mejores resultados que modelos entrenados desde cero para el mismo aeropuerto.

6. Valoración del documento original

Este paper cuenta con una introducción que nos introduce en la problemática derivada de la variante capacidad de los aeropuertos debido a causas externas, lo cual hace que se entienda desde un principio el motivo del estudio. Además, las diferentes métricas y gráficas de representación de resultados a lo largo del paper, muestra de manera visual los buenos resultados obtenidos.