

MODELO BASADO EN REDES NEURONALES RECURRENTE LSTM PARA LA PREDICCIÓN DE LA SIGUIENTE ACTIVIDAD EN PROCESOS DE NEGOCIO

LSTM RECURRENT NEURAL NETWORK BASED-MODEL FOR THE PREDICTION OF THE NEXT ACTIVITY IN BUSINESS PROCESSES

Ulises Manuel Ramírez Alcocer

Universidad Autónoma de Tamaulipas
a2093010066@alumnos.uat.edu.mx

Edgar Tello-Leal

Universidad Autónoma de Tamaulipas
etello@uat.edu.mx

Ana Bertha Ríos Alvarado

Universidad Autónoma de Tamaulipas
arios@docentes.uat.edu.mx

Resumen

Las redes neuronales recurrentes de tipo Memoria a Corto y Largo Plazo (LSTM) proporcionan una alta precisión en la predicción del modelado de secuencias en varios dominios de aplicación. En este artículo se introduce el uso de redes LSTM para la predicción de actividades de un proceso de negocio, etapa importante dentro del descubrimiento de procesos de negocio en la minería de procesos. Se propone una metodología para la implementación de la red LSTM en el dominio de minería de procesos. La red neuronal LSTM es entrenada con diferentes registros de eventos para comparar su tasa de exactitud, los registros de eventos presentan diferente cantidad de trazas, número de casos y total de actividades. La tasa de exactitud obtenida en el entrenamiento de la red neuronal es aceptable de acuerdo a la literatura del dominio, así como la validación de la precisión en la predicción de la siguiente actividad.

Palabras Claves: LSTM, minería de procesos, red neuronal, registro de eventos.

Abstract

The Long Short-Term Memory (LSTM) Recurrent Neural Networks provide a high precision in the prediction of the modeling of sequences in several application domains. This article introduces the use of LSTM networks for the prediction of activities in a business process, an important step in the discovery of business processes in process mining. A methodology for the implementation of the LSTM network in the process mining domain is proposed. The LSTM neural network is trained with different event logs to compare its accuracy rate, the event logs contain a different number of traces, number of cases and total activities. The accuracy rate obtained in the training of the neural network is acceptable according to the literature of the domain, as well as the validation precision in the prediction of the next activity.

Keywords: Event log, LSTM, neural network, process mining.

1. Introducción

Actualmente, en una economía basada en el conocimiento, las organizaciones públicas o privadas, requieren realizar una gestión de activos de conocimiento apropiada para mantener una ventaja competitiva en los mercados globales o en los servicios gubernamentales. En este ámbito la gestión de procesos de negocio ha recibido considerable atención recientemente por las comunidades de investigación de ciencias de la computación y administración de negocios.

Las tecnologías de información en general y los sistemas de información en particular desempeñan un rol importante en la gestión de procesos de negocio, debido a que una gran cantidad de actividades que las organizaciones realizan son soportadas por los sistemas de información. Varios tipos de actividades contenidas en los procesos de negocio pueden ser ejecutadas automáticamente por los sistemas de información, sin la participación de un humano. Un *proceso de negocio* consiste de un conjunto de actividades que son realizadas en forma coordinada en una organización en un ambiente técnico, y estos procesos de negocio tienen correlacionada al menos una meta de negocio [Weske, 2012]. El lenguaje estándar para modelar procesos de negocio es la Notación para el Modelado de Procesos

de Negocio (BPMN, del inglés *Business Process Model and Notation*) [Object, 2011].

Las técnicas de minería de procesos son capaces de extraer conocimiento a partir de los registros de eventos, comúnmente disponibles en los sistemas de información. Estas técnicas proporcionan nuevos medios para *descubrir, monitorear, y mejorar* los procesos de negocio en una variedad de dominios de aplicación. Existen dos factores principales para el creciente interés en la minería de procesos. Por un lado, cada vez más eventos se registran, proporcionando información detallada sobre la historia de los procesos de negocio. Por otro lado, existe una necesidad de mejorar y dar soporte a los procesos de negocio en entornos competitivos y rápidamente cambiantes.

En la minería de procesos se asume que es posible registrar eventos secuencialmente, dado que cada evento tiene referencia a una *actividad* y se relaciona a un caso en particular (una instancia del proceso) [Aalst, 2012]. Entonces, los datos de entrada en la minería de procesos es un registro de eventos. Un *registro de eventos* es un archivo estructurado jerárquicamente con datos sobre las ejecuciones de procesos de negocio [Baier, 2014]. Este archivo contiene datos sobre varias ejecuciones del mismo proceso de negocio. Un *evento* es la parte atómica de ejecución de un proceso específico y puede contener una gran cantidad de atributos. Los *datos de eventos*, generados por los sistemas de información, normalmente se encuentran como actualizaciones de un estado (por ejemplo, del estado “factura enviada” cambia al estado “factura pagada”), o también como registros de actividad (por ejemplo, “correo electrónico enviado al cliente”). Una *traza* es un conjunto de eventos que pertenecen a la misma ejecución de un proceso de negocio. Por lo tanto, los registros de eventos pueden contener información adicional de los eventos, tales como el usuario que ejecuta la actividad o el dispositivo que inicia la actividad, la hora en que inició el evento, la duración del evento, entre otras.

Las principales tareas de minería de procesos son descubrimiento, conformidad y mejoramiento de procesos. El *descubrimiento de procesos* consiste en utilizar un registro de eventos como entrada y producir un modelo de procesos de negocio

sin usar información a-priori [Aalst, 2016]. El modelo descubierto normalmente es un modelo de proceso de negocio que es representado usando una notación gráfica como el lenguaje BPMN [Object, 2011], redes de Petri [Jensen, 2009], [Tello-Leal, 2014], cadenas de procesos basadas en eventos (EPC, del inglés *Event-driven Process Chains*) [Gottschalk, 2008], o diagramas de actividades de UML. La *conformidad de procesos* consiste en comparar un modelo de proceso de negocio con el registro de eventos generado por la ejecución de mismo modelo de proceso [Aalst, 2016]. La verificación de conformidad puede ser utilizada para evaluar si la información almacenada en el registro de eventos es equivalente al modelo y viceversa. El *mejoramiento de procesos* consiste en extender o mejorar un modelo de proceso existente usando la información almacenada del proceso actual en el registro de eventos. La arquitectura de red neuronal recurrente (RNN) se ha convertido en un modelo de red neuronal implementado en diferentes dominios, debido a su capacidad natural para procesar entradas secuenciales y conocer sus dependencias a largo plazo [Wei, 2018]. A diferencia de la red neuronal feed-forward, las neuronas de RNN están conectadas entre sí en la misma capa oculta y se aplica una función de entrenamiento a los estados ocultos repetidamente [Wei, 2018]. En este sentido, la red neuronal de Memoria a Corto y Largo Plazo (LSTM, del inglés *Long Short-Term Memory*) es una extensión de la RNN, la cual ha logrado excelente rendimiento en diversas tareas, especialmente en problemas secuenciales [YiFei, 2018], [Cortez, 2018], [Liu, 2018].

Un requerimiento importante en la gestión de procesos de negocio es tener sistemas de información con capacidad para predecir el comportamiento futuro de un proceso de negocio [Evermann, 2017]. Es decir, métodos predictivos de monitoreo de procesos negocio que explotan los registros de eventos para hacer predicciones sobre casos de ejecución de los mismos [Tax, 2017]. Por lo tanto, la implementación de redes neuronales LSTM para el descubrimiento de eventos o actividades de un proceso de negocio mediante un análisis predictivo, se puede considerar una estrategia importante como una técnica de la minería de procesos. En el presente artículo se propone un enfoque para el descubrimiento de procesos de negocio a partir de trazas contenidas en un registro de eventos. El

descubrimiento se realiza mediante una técnica de modelado predictivo para procesos de negocio. El modelo predictivo se basa en una red neuronal recurrente LSTM que es entrenada con un registro de eventos, habilitando la predicción de la actividad siguiente derivada de una actividad de entrada o un conjunto de actividades. La red neuronal LSTM presenta una tasa de exactitud altamente aceptable, lo cual permite predecir una actividad con un porcentaje de precisión máximo. La red neuronal LSTM fue entrenada con diferentes registros de eventos, comportándose en forma similar para todos los casos.

2. Métodos

Registro de eventos

El componente importante en los enfoques de la minería de procesos es la utilización de registros de eventos para descubrir modelos de procesos de negocio. El formato estándar para contener un registro de evento es un documento XES (del inglés, *eXtensible Event Stream*) [Aalst, 2016]. Un documento XES (basado en XML) contiene un registro que consta de cualquier cantidad de trazas. Cada traza describe una lista secuencial de eventos correspondientes a un caso particular. El registro, sus trazas y sus eventos pueden tener cualquier cantidad de atributos. Los atributos pueden estar anidados, limitado a cinco tipos: cadena, *fecha*, entero, *flotante* y *booleano*. En la figura 1 se muestra un extracto de un registro de eventos basado en el estándar XES.

```
</trace>
<trace>
  <string key="concept:name" value="Case1.37"/>
  <event>
    <string key="org:resource" value="UNDEFINED"/>
    <date key="time:timestamp" value="2010-10-27T22:31:19.526+02:00"/>
    <string key="concept:name" value="a"/>
    <string key="lifecycle:transition" value="complete"/>
  </event>
  <event>
    <string key="org:resource" value="UNDEFINED"/>
    <date key="time:timestamp" value="2010-10-27T22:32:19.526+02:00"/>
    <string key="concept:name" value="c"/>
    <string key="lifecycle:transition" value="complete"/>
  </event>
  <event>
    <string key="org:resource" value="UNDEFINED"/>
    <date key="time:timestamp" value="2010-10-27T22:33:19.526+02:00"/>
    <string key="concept:name" value="d"/>
    <string key="lifecycle:transition" value="complete"/>
  </event>
</trace>
```

Figura 1 Extracto de registro de eventos.

Metodología

La metodología que se propone utilizar en la implementación de una red neuronal LSTM para predecir la actividad siguiente a partir de un registro de eventos, generados de la ejecución de procesos de negocio se conforma de tres fases:

- Pre-procesamiento del registro de eventos.
- Categorización.
- Modelo de predicción basado en LSTM, tal como se muestra en la figura 2.

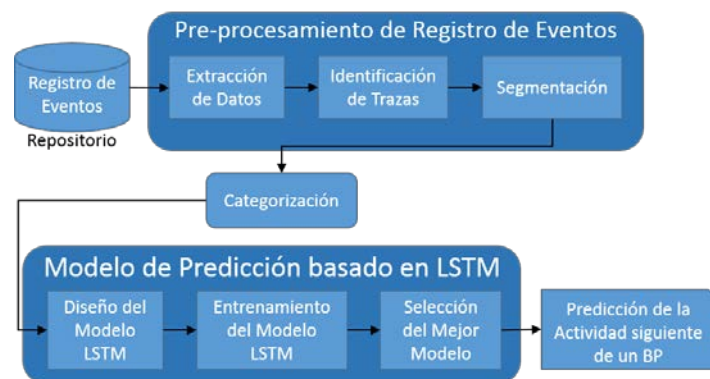


Figura 2 Esquema de la metodología propuesta.

La fase de pre-procesamiento del registro de eventos se compone de las siguientes etapas:

- **Extracción de datos.** Se realiza un análisis detallado de los registros de eventos en el formato .xes, el cual permite la identificación de los diferentes atributos que contiene el registro de eventos, permitiendo seleccionar los atributos requeridos para una predicción, en este caso se utiliza el atributo “actividad”.
- **Identificación de trazas.** Consiste en identificar y obtener las trazas, con sus respectivos eventos. A continuación, se agregan en un archivo de texto, manteniendo su orden de aparición.
- **Segmentación.** Al archivo de texto generado en la etapa anterior se le aplica una tarea de segmentación, que consiste en crear una lista de todos los eventos de una traza, utilizando un criterio de separación entre cada evento.

A continuación, cada evento es convertido en un número entero único, posteriormente, las trazas son convertidas en una secuencia de números enteros, posibilitando generar una lista de secuencia de “números enteros” conformada de *actividades de entrada* (X) y *actividades de salida* (Y). Entonces, la lista de secuencia se divide en dos listas, la primera contiene la secuencia de *actividades de entrada* (X). La segunda lista almacena los enteros correspondientes a la *actividad de salida* (Y) de cada secuencia. Finalmente, la lista de secuencia de *actividades de entrada* es transformada en una matriz de dos dimensiones (número de secuencias, máxima longitud de secuencias).

La fase intermedia de **categorización** consiste en un proceso para categorizar la secuencia de números enteros correspondiente a las *actividades de salida* (Y) en una representación de tipo “*one hot encoding*”, especificando que el número de clases será igual al tamaño del vocabulario. La fase de modelo de predicción basado en LSTM se compone de las siguientes etapas:

- **Diseño de la red.** se genera el diseño de la red LSTM, por capas, primero se genera la capa de entrada (*embedding*), luego la capa oculta (unidades LSTM), finalmente la capa de salida, en cada una de estas capas, se definen los parámetros necesarios.
- **Entrenamiento de la red.** El entrenamiento de la red LSTM se realiza utilizando como datos entrenamiento la secuencia de números representadas por las actividades contenidas en la matriz (X) y en la representación “one hot” (Y).
- **Selección del modelo.** Los resultados del entrenamiento permitirán elegir el modelo de la red LSTM como modelo final a implementar. Un entrenamiento con un grado de exactitud alto se deberá seleccionar como el modelo para realizar las predicciones. En caso contrario, se recomienda modificar el diseño de la red, ajustando los parámetros requeridos y ejecutar nuevamente el entrenamiento de la red.
- **Predicción.** Es la salida generada por la red neuronal LSTM, la cual mediante una fase de entrenamiento permite predecir la actividad siguiente

en un proceso de negocio, a partir de una actividad de entrada o de una secuencia de actividades de entrada, lo cual se explica en los siguientes apartados del documento.

Bases de la Implementación

El enfoque propuesto se basa en la ejecución de una red neuronal recurrente LSTM, que es considerada como una red de estructura especial que consisten en bloques de memoria y celdas de memoria, junto con las unidades de compuerta que las contienen [Sak, 2015], es decir, una unidad LSTM se compone de una celda y tres compuertas (entrada, salida y olvido). Mediante esta estructura especial una red LSTM puede seleccionar qué información se olvida o se recuerda. Las unidades de compuerta de entrada multiplicativas se usan para evitar los efectos negativos que las entradas no relacionadas pueden crear. La compuerta de entrada controla el flujo de entrada a la celda de memoria, y la compuerta de salida controla la secuencia de salida de la celda de memoria a otros bloques LSTM.

La compuerta de olvido en la estructura del bloque de memoria está controlada por una red neuronal simple de una capa. En un momento t , los componentes de la unidad LSTM se actualizan mediante ecuación 1 [Hochreiter, 1997], [Cortez, 2018].

$$f_t = \sigma(W[x_t, h_{t-1}, C_{t-1}] + b_f) \quad (1)$$

Donde x_t es la secuencia de entrada, h_{t-1} es la salida de bloque anterior, c_{t-1} es la memoria de bloque LSTM anterior, y b_f es el vector de polarización. W representa vectores de peso separados para cada entrada y σ es la función sigmoidea logística. La función de activación sigmoidea, que es la salida de la compuerta de olvido, se aplica al bloque de memoria anterior mediante la multiplicación por elementos. Por lo tanto, se determina el grado en que el bloque de memoria previo será efectivo en el LSTM actual. Si el vector de salida de activación contiene valores cercanos a cero, se olvidará la memoria anterior.

La otra compuerta, la compuerta de entrada, es una sección donde la nueva memoria es creada por una red neuronal simple con la función de activación \tanh

y el bloque de memoria anterior. Estas operaciones se calculan mediante las ecuaciones 2 y 3.

$$i_t = \sigma(W[x_t, h_{t-1}, C_{t-1}] + b_i) \quad (2)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tanh(W[x_t, h_{t-1}, C_{t-1}] + b_c) \quad (3)$$

Finalmente, la compuerta de salida es la sección en donde se genera las probabilidades del bloque LSTM actual [Cortez, 2018]. Las salidas se calculan mediante las ecuaciones 4 y 5.

$$o_t = \sigma(W[x_t, h_{t-1}, C_t] + b_o) \quad (4)$$

$$h_t = \tanh(C_t) \cdot o_t \quad (5)$$

3. Resultados

En la implementación de la red neuronal LSTM se utilizó una librería de Python denominada Keras [Chollet, 2015], la cual permite construir modelos de redes de aprendizaje profundo (*deep learning*). Los parámetros de implementación de la red LSTM se presentan en la tabla 1.

Tabla 1 Parámetros de configuración de la red neuronal LSTM.

Parámetro	Valor
epochs	500
batch_size	20
optimizer	Adam
loss	categorical_crossentropy
LSTM_units	50

En la figura 3 se presenta un extracto del registro de eventos utilizado para entrenar la red neuronal LSTM, el cual corresponde al Log_5 de la tabla 2.

```

1 a b e f
2 a b e c d b f
3 a b c e d b f
4 a b e c d b f
5 a e b c d b f
6 a b c d e b f
7 a b c d e b f
8 a b e f
9 a b e c d b f
10 a e b c d b f
11 a e b c d b f
12 a b e f
    
```

Figura 3 Extracto de un registro de evento.

Tabla 2 Valores de la red neuronal LSTM.

Registro	Trazas	Número de Casos	Total de Actividades	Actividades Máximas por Caso	Tasa de Exactitud	Validación de la Precisión
Log_1	35	3	5	4	0.8889	0.8990
Log_2	13	6	6	12	0.8202	0.9787
Log_3	4	3	7	16	0.8919	0.9000
Log_4	147	4	5	3	0.7175	0.7090
Log_5	14	5	6	7	0.7889	0.8000
Log_6	11	4	6	4	0.9048	0.8910
Log_7	8	4	3	6	0.7600	0.7500
Log_8	6	3	4	7	0.7917	0.7620
Log_9	200	4	4	3	0.9916	0.9575
Log_10	1391	21	8	17	0.8055	0.7000

En la tabla 2 se presenta los resultados obtenidos por la red neuronal LSTM, representados mediante la tasa de exactitud y el porcentaje de predicción. La columna “Registro” representa el documento XES (registro de evento) utilizada para entrenar la red LSTM. La columna “Trazas” es el número de trazas contenidas en el registro. La columna “Número de Casos” representa el comportamiento que se puede identificar del modelo de proceso de negocio, de acuerdo a las trazas contenidas en el registro de eventos. En la columna “Total de Actividades” representa el número de actividades diferentes contenidas en el registro de eventos. La columna “Validación de la Precisión” representa la capacidad de la red para predecir la siguiente actividad.

Las pruebas realizadas a la red LSTM entrenada permiten comprobar que tienen capacidad para predecir la siguiente *actividad* de un modelo de proceso de negocio. La red LSTM acepta como dato de entrada de *una actividad* hasta *cuatro actividades*, prediciendo en todos los casos la siguiente *actividad* de la secuencia recibida en la entrada. El aumento en la precisión que se muestra en la tabla 2 se puede justificar debido a que el conjunto de datos consiste en secuencias más largas de palabras (eventos) idénticas, lo que hace mucho más fácil la predicción de la siguiente actividad, este tipo de resultados se han presentado en otros trabajos relacionados a la predicción del siguiente evento o actividad en procesos de negocio utilizando redes neuronales LSTM [Evermann, 2017].

En la tabla 3 se presenta un extracto de los resultados obtenidos en la predicción de la red neuronal utilizando el Log_5 presentado en la tabla 2, en la columna

“Actividad Esperada” se muestran las actividades con mayor probabilidad de respuesta por la red neuronal, en base a los pesos de cada actividad.

Tabla 3 Extracto de la predicción generada por la red neuronal LSTM.

No.	Actividad de Entrada	Actividad Esperada	Actividad de Salida
1	c	d e	D
2	b	c e	C
3	a	b e	B
4	a b	e c	E
5	a e	b	B
6	e b	c	C
7	c d	b e	B
8	b c	d e	D
9	a b e	f c	F
10	c d e	b	B

4. Discusión

En el presente trabajo se ha identificado un área de oportunidad en la cual se pueden implementar redes neuronales recurrentes de tipo LSTM. También, presenta una metodología para la implementación de una red neuronal recurrente para el descubrimiento de modelos de procesos de negocio, en específico predecir la siguiente actividad, como técnica de la minería de procesos. La metodología permite identificar las fases requeridas para predecir la actividad o evento siguiente, mediante la implementación de la red neuronal LSTM.

Cabe mencionar que las trazas en un registro de eventos están en un orden particular, pero este es un orden arbitrario. Entonces, debido a que las celdas LSTM mantienen el estado, el orden en que se usan las trazas para entrenar la red puede tener un efecto en el resultado. Además, la selección del conjunto de trazas de un registro de eventos, datos de entrenamiento, tiene una influencia, y los resultados obtenidos con una muestra particular pueden no generalizarse a otros casos (registros de eventos), tal como se presenta en tasa de exactitud (tabla 2).

El análisis predictivo implementado permite obtener información útil para descubrir un modelo de proceso de negocio a partir de registros de evento. Ciertamente, es necesario explorar con otros registros de eventos con mayor cantidad de trazas, así como considerar incluir dos o más clases para predecir la siguiente actividad o evento.

5. Conclusiones

En este artículo se presentó el diseño de un enfoque de método predictivo para datos contenidos en los registros de eventos de procesos de negocio utilizando un enfoque de red neuronal recurrente LSTM. La aplicación de esta técnica es novedosa en el campo de la minería de procesos de negocio. Al usar registros de eventos para el entrenamiento de la red neuronal LSTM con datos sintéticos y del mundo real, se demuestra que el método predictivo puede ser efectivo, presentando una tasa de exactitud aceptable, en todos los casos de estudio.

En nuestro punto de vista, la variación en la tasa de exactitud que se presenta dependiendo del registro de eventos utilizado para el entrenamiento de la red neuronal recurrente LSTM, se debe a la cantidad de casos que contiene el registro de eventos, así como la cantidad de trazas contenidas en el registro, lo cual puede influir en la predicción de la actividad siguiente, realizada por la red neuronal. Un trabajo futuro por atender es ampliar la matriz de vectores de características con casos adicionales y atributos contenidos en el registro de eventos adicionales, por ejemplo, marcas de tiempo y recursos.

Este trabajo ha sido financiado por la beca 26328 del proyecto de Investigación de Ciencia Básica SEP-CONACYT CB_2015/256922.

6. Bibliografía y Referencias

- [1] Baier, T., Mendling, J., Weske, M. Bridging abstraction layers in process mining. *Information Systems*, 46(6), 123-139, 2014.
- [2] Chollet, F. Keras. <https://github.com/fchollet/keras>, 2015.
- [3] Cortez, B., Carrera, B., Kim, Y. J., Jung, J. Y. An architecture for emergency event prediction using LSTM recurrent neural networks. *Expert Systems with Applications*, 97, 315-324, 2018.
- [4] Evermann, J., Rehse, J. R., Fettke, P. Predicting process behaviour using deep learning. *Decision Support Systems*, 100, 129-140, 2017.
- [5] Gottschalk, F., van der Aalst, W., Jansen-Vullers, M. Merging event-driven process chains. In Meersman, R., Tari, Z., eds. *On the Move to Meaningful Internet Systems: OTM 2008*. Springer Berlin Heidelberg, 418-426, 2008.

- [6] Hochreiter, S., Schmidhuber, J. Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780, 1997.
- [7] Liu, F., Chen, Z., Wang, J. Video image target monitoring based on RNN-LSTM. *Multimedia Tools and Applications*, 1-18, 2018.
- [8] Jensen, K., Kristensen, L.M. *Coloured Petri Nets: Modelling and Validation of Concurrent Systems*. Springer-Verlag Berlin Heidelberg, Berlin, Germany. 2009.
- [9] Object Management Group. *Business process model and notation version 2.0. Specification formal/2011-01-03*, Object Management Group, 2011.
- [10] Sak, H., Senior, A., Beaufays, F. Long short-term memory recurrent neural network architectures for large scale acoustic modeling. In *Fifteenth Annual Conference of the International Speech Communication Association*, 2014.
- [11] Tax, N., Verenich, I., La Rosa, M., Dumas, M. Predictive Business Process Monitoring with LSTM Neural Networks. In *Advanced Information Systems Engineering*, Dubois, E., Pohl, K., eds., Springer, 477-492, 2017.
- [12] Tello-Leal, E., Chiotti, O., Villarreal, P.D. Software agent architecture for managing inter-organizational collaborations. *Journal of Applied Research and Technology*, 12(3), 513-526, 2014.
- [13] van der Aalst, W., Adriansyah, A., de Medeiros, A.K.A., et al. Process mining manifesto. In Daniel, F., Barkaoui, K., Dustdar, S., eds. *Business Process Management Workshops*. Springer Berlin Heidelberg, 169-194, 2012.
- [14] van der Aalst, W. *Process Mining: Data Science in Action*, 2nd edn. Springer. New York, USA. 2016.
- [15] Wei, X., Wen Z., Bo L., Min C., Lijun C., Lei H. Novel architecture for long short-term memory used in question classification. *Neurocomputing*, 299, 20-31, 2018.
- [16] Weske, M. *Business Process Management: Concepts, Languages, Architectures*, 2nd edn. Springer, Berlin, Germany. 2012.
- [17] YiFei, L., Han C. Prediction for Tourism Flow based on LSTM Neural Network. *Procedia Computer Science*, 129, 277-283, 2018.