

Pronóstico de Mediciones Eléctricas utilizando aprendizaje de máquina cuántico

DOI: 10.29236/sistemas.n173a4

Jonathan J. Montes Campos, Daniel Sierra Sosa, Juan G. Lalinde Pulido

1. Conceptos Básicos sobre Telemida en el sector eléctrico

La telemida es un conjunto de actividades que hacen parte del subproceso de aseguramiento de ingresos en las empresas del sector eléctrico. Utiliza plataformas de software y hardware especializadas que permiten el acceso remoto a los datos capturados por los me-

didores habilitados para ello, con el propósito de hacer análisis y crítica de los consumos de los clientes y registros de energía generada por las centrales de generación de energía. En este trabajo se presenta un experimento desarrollado en conjunto con EPM - Empresas Públicas de Medellín E.S.P., en el cual se usa computación cuántica para predecir valores futuros de las mediciones eléctricas.

La Telemida se hace utilizando redes de comunicación de datos que permiten obtener las medidas de consumos y generación acorde con las exigencias normativas: cada 15 minutos en generación y cada 60 minutos para consumos de clientes.

El marco regulatorio que dicta normas con respecto a la gestión de la medida y telemida está dado por: Leyes de servicios públicos 142 y 143, Resolución CREG 038 de 20-14 código de medida.

La medición, es decir la toma de las medidas de los medidores, se puede llevar a cabo mediante dos estrategias: la medición tradicional y la telemida. En la medición tradicional es presencial y física en cambio, en la telemida, la tecnología incluye el uso de redes de datos para acceder a la información del medidor, lo cual permite:

- Predecir la generación de energía.
- Gestionar la entrega de excedentes de energía generada al sistema interconectado.
- Predecir la demanda de energía.
- Detectar anomalías en las lecturas registradas en los medidores.
- Detectar variaciones en las frecuencias de lectura, cálculo de consumos y facturación.

- Optimizar la eficiencia energética.
- Mejorar el relacionamiento con los clientes mediante recomendaciones que optimicen su uso de energía.

2. Experimento

2.1 Descripción y Alcance del Experimento

Partiendo de la problemática para la gestión de la telemida, descrita anteriormente, se plantea la realización de un experimento para verificar si las métricas de rendimiento, calidad y tiempos de procesamiento, que se obtienen utilizando la computación clásica se mantienen o mejoran al usar la computación cuántica.

Para realizar este experimento se requiere la implementación de modelos de gestión de información a partir de algoritmos de computación clásica y cuántica, y el uso de computadores clásicos y computadores cuánticos.

2.2 Diseño Experimental

En este diseño se definen los elementos o parámetros necesarios para el desarrollo del algoritmo para computación clásica y para el algoritmo de computación cuántica, lo cual permite evaluar y comparar los resultados de ambos escenarios para poder sacar conclusiones.

El *dataset* utilizado contiene 2,765,004 lecturas pertenecientes a 1,925 medidores, y tiene la siguiente estructura (Tabla 1).

La infraestructura de cómputo utilizada fue la siguiente (Tabla 2).

3. Modelos de Pronóstico

Generalmente, el pronóstico de carga se centra en la carga eléctrica total por hora, pero puede extenderse a la predicción de cargas del sistema por hora, diaria, semanal y mensual, incluidas las cargas máximas. Los pronósticos se clasifican según el horizonte temporal en: pronóstico de carga a corto plazo (STLF) para hasta un día; a mediano plazo (MTLF) para entre un día y un año; y a largo plazo (LTLF) para entre uno y diez años. Para sistemas grandes como redes regionales o nacionales, estos modelos logran una precisión relativamente alta [1] [2].

Diferentes investigaciones han demostrado que las técnicas cuantitativas de pronóstico, como promedios móviles [3], series temporales [4] y métodos de aprendizaje profundo [5], son útiles cuando la situación es estable y se dispone de datos previos, como es el caso de este experimento. Por otra parte, otras investigaciones sugieren que las técnicas tradicionales de análisis de series temporales, como modelos de regresión, ARIMA, GARCH y modelos híbridos que combinan ARIMA y GARCH con

transformadas wavelet, no son adecuadas para pronósticos a corto plazo en configuraciones de datos de alta dimensión o alta volatilidad [6], ya que estos métodos a menudo tienen dificultades con la escalabilidad y la adaptabilidad en tales contextos.

En contraste, las redes neuronales artificiales (ANNs) son más aptas para manejar la complejidad de los pronósticos a corto plazo ya que sus capas ocultas y capacidades de aprendizaje identifican y explotan patrones ocultos en datos de series temporales, lo que lleva a pronósticos más precisos. Estas son particularmente valoradas por varias características clave:

1. Robustez: Las ANNs pueden generalizar bien incluso con datos incompletos o ruidosos.
2. Naturaleza no paramétrica: No requieren suposiciones predefinidas sobre la distribución de los datos, lo que las hace flexibles en diversas aplicaciones. En general, en problemas de ciencia de datos, esta es una aproximación que a menudo se pasa por alto, y se asume una distribución normal en los datos, lo cual no es cierto en todos los casos.
3. Aproximación universal: Las ANNs pueden modelar cualquier función continua con el nivel de precisión deseado.

Los avances recientes en el pronóstico de carga a corto plazo han visto la integración de técnicas

Variable	Descripción	Valores
SERIE	Identificador único del cliente o medidor eléctrico.	Numérico (ej., 18741849).
FECHA	Fecha de la medición. Va desde el 2023-06-01 hasta el 2023-07-31	Formato YYYY-MM-DD.
HORA	Hora de la medición. Va de 0 a 23 horas del día.	Numérico (0, 1, 2, ..., 23).
SERVICIO_SUSCRITO	Servicio suscrito, identificado por un código numérico (ej., Residencial, Industrial)	Numérico (ej., 130820443 corresponde a la categoría Industrial con subcategoría 11-220 Voltios).
ACTIVA_IMP	Energía activa importada (kWh).	Numérico (ej., 0.33).
REACTIVA_IMP	Energía reactiva importada (kVARh).	Numérico (ej., 0.04).
ACTIVA_EXP	Energía activa exportada (kWh).	Numérico (ej., 0.03).
REACTIVA_EXP	Energía reactiva exportada (kVARh)	Numérico (ej., 0.05).
V1, V2, V3	Voltaje de las fases 1, 2 o 3 (V).	Numérico (ej., 230.5).
I1, I2, I3	Corriente de las fases 1, 2 o 3 (A).	Numérico (ej., 13.2).
ALARM.NAME	Nombre de la alarma activada durante la medición.	Alfanumérico (ej., Overload).
CATEGORÍA	Categoría de la medición	1: RESIDENCIAL. 2: COMERCIAL. 3: INDUSTRIAL. 4: OFICIAL. 5: ESPECIAL. 7: AUTOCONSUMO.
SUBCATEGORÍA	Subcategoría de la medición.	1: ESTRATO 1. 2: ESTRATO 2. 3: ESTRATO 3. 4: ESTRATO 4. 5: ESTRATO 5. 6: ESTRATO 6. 11-220 Voltios. 12: 132000 Voltios.
X, Y	Coordenadas de latitud y longitud, respectivamente.	Numérico (ej., -74.00597, 40.71278).

Tabla 1. Variables del dataset

Tipo de infraestructura	Descripción
Clásica:	laptop personal
Clásica para simulación cuántica con GPU:	Centro de Computación Científica Apolo: Cola Accel-2 con 3 GPU habilitadas para el experimento
Clásica para simulación cuántica con CPU:	Centro de Computación Científica Apolo: Cola longjobs, nodo con 32 núcleos.
Computador cuántico:	IBM, 127 qubits.

Tabla 2. Infraestructura computacional

avanzadas de aprendizaje automático. En China, un modelo híbrido que combina descomposición por modo de variación (VMD) con redes de memoria a corto y largo plazo (LSTM), con optimización bayesiana (BOA), presentó un rendimiento superior, logrando un MAPE de 0.4186 % y un coeficiente R^2 de 0.9945, comparado con otros modelos como SVR, regresión MLP, LR, RF y EMD-LSTM [7].

Las redes neuronales artificiales (ANNs) han sido utilizadas de manera efectiva para pronosticar la carga a corto plazo, especialmente con datos no lineales. En [8], por ejemplo, los autores desarrollaron un modelo basado en ANNs para procesar conjuntos grandes de datos históricos de carga, dinámicos y no lineales, contrastando los resultados en una instalación real de pruebas. Otras arquitecturas de redes neuronales, incluidas las RNNs, CNNs, LSTMs y redes profundas, también se han utilizado

para mejorar la precisión de los pronósticos [9]. En particular, las redes LSTM han demostrado superar a los enfoques estadísticos y de aprendizaje automático tradicionales en la reducción de los errores de predicción [10], mostrando específicamente que los modelos LSTM son efectivos para el pronóstico de carga residencial a corto plazo y superando significativamente a modelos como ELM, BP-NN y regresión de k-vecinos más cercanos.

En este trabajo, se propone un método para el pronóstico preciso de la carga eléctrica a corto plazo, para las siguientes 24 horas y la siguiente semana, para hogares individual agrupados por clase social y para la industria. Inicialmente se aplicaron modelos LSTM clásicos para evaluar sus capacidades de pronóstico con diferentes grupos de usuarios y para evaluar las dependencias e independencias de los grupos en el pronóstico de se-

ries temporales. Este enfoque clásico fue la base para el desarrollo de modelos LSTM mejorados cuánticamente (QLSTM) y también se utilizó como línea base para la comparación.

Como en el aprendizaje automático (ML), los paradigmas QML pueden clasificarse en aprendizaje supervisado o basado en tareas, aprendizaje no supervisado o basado en datos, y aprendizaje reforzado o basado en recompensas. Debido a su resiliencia al ruido, buena generalización y su potencial para aprovechar la ventaja cuántica, el aprendizaje supervisado ha recibido especial atención en los últimos años [11]. Los algoritmos QML aceleran los sistemas cuánticos para mejorar las tareas de regresión o clasificación de ML, por ejemplo, mediante el Support Vector Machine Cuántico, PCA Cuántico, Clasificador Cuántico Variacional, Máquina Boltzmann Cuántica, Red Neuronal Cuántica (QNN), Red Neuronal Convolutiva Cuántica y Red Neuronal Profunda Cuántica [12].

Las redes neuronales cuánticas (QNNs) se refieren a la utilización de circuitos cuánticos parametrizados, que son una secuencia de compuertas, algunas de las cuales tienen parámetros libres, que serán entrenados para resolver el problema. Este algoritmo merece especial atención ya que se utiliza en los tres paradigmas de QML: aprendizaje supervisado, aprendi-

zaje no supervisado y aprendizaje reforzado. En algunos casos, se utilizan enfoques híbridos con modelos que combinan redes neuronales clásicas y cuánticas, los cuales buscan distribuir la capacidad de representación y la complejidad computacional entre la computación clásica y cuántica. En otros casos se han propuesto versiones cuánticas de métodos de núcleo (kernel) [11].

Los computadores cuánticos actuales, particularmente los dispositivos cuánticos de escala intermedia ruidosos (NISQ), enfrentan dificultades para ejecutar circuitos cuánticos con muchos qubits o con muy profundos debido a la falta de mecanismos efectivos de corrección de errores cuánticos [13]. Para abordar este problema, un trabajo reciente de investigadores chinos introduce un nuevo marco que utiliza Circuitos Cuánticos Variacionales (VQC) para implementar Redes Neuronales Recurrentes (RNNs), específicamente redes de Memoria a Largo Corto Plazo (LSTM). Su enfoque, denominado LSTM Cuántico (QLSTM), combina computación cuántica y clásica para aprovechar el poder expresivo del entrelazamiento cuántico mientras mantiene la viabilidad práctica para dispositivos NISQ. Este marco híbrido cuántico-clásico presenta resultados prometedores, incluyendo un aprendizaje más rápido y una convergencia más estable en comparación con las LSTM clásicas y ha sido utilizado en varias aplica-

ciones físicas [13] y en la predicción de irradiancia solar [14]. Además, los VQC se han utilizado para algoritmos cuánticos poco profundos, siendo exitosos en tareas de clasificación, agrupamiento e incluso aprendizaje por refuerzo profundo [14].

Basándose en estos avances, este en este trabajo se utiliza el QLSTM, logrando un desempeño mejor en términos de función de pérdida, aprendiendo más rápido, aproximadamente en la mitad de las épocas que el LSTM clásico, en el contexto de pronóstico de mediciones de carga eléctrica. A continuación, se presentan los modelos LSTM y QLSTM con el fin de clarificar la relación que hay entre ellos.

3.1 LSTM

Las redes de Memoria a Largo Plazo (LSTM) fueron introducidas por Sepp Hochreiter y Jürgen Schmidhuber para abordar los problemas de memoria inherentes a las Redes Neuronales Recurrentes (RNNs) [15], [16]. Las RNNs tienen la capacidad de mantener una forma de memoria a corto plazo, lo que les permite procesar secuencias de datos. Sin embargo, tienen dificultades para retener información a lo largo de secuencias largas debido al problema del gradiente que desaparece, lo que lleva a la pérdida de información importante a medida que pasa por múltiples pasos. Esto hace que sea un desafío para las RNNs aprender dependencias

a largo plazo en las secuencias de datos [16].

Las LSTM se desarrollaron para aliviar estos problemas. Una célula LSTM es similar a una célula RNN estándar, pero introduce dos vectores separados: $h(t)$, el estado a corto plazo, y $c(t)$, el estado a largo plazo. Estos dos vectores trabajan junto para retener y descartar selectivamente información a lo largo de la secuencia, lo que permite a la red aprender dependencias a lo largo de períodos de tiempo más largos. La estructura de una célula LSTM incluye tres componentes principales llamados puertas: la Puerta de Olvido, la Puerta de Entrada y la Puerta de Salida, como se ve en la Figura 1.

La Puerta de Olvido determina qué información del estado a corto plazo anterior y la entrada actual debe ser descartada, la Puerta de Entrada procesa la información que recibe la neurona y obtiene ciertas características de la etapa actual de la secuencia, mientras que la Puerta de Salida se encarga de definir qué información se guardará para el término a corto plazo para el siguiente paso en la secuencia. Usando las Puertas de Olvido, de Entrada y de Salida, las LSTMs retienen selectivamente la información relevante mientras descartan detalles menos importantes, de manera similar a cómo el cerebro humano simplifica y retiene información esencial mientras descarta detalles menos relevantes [13].

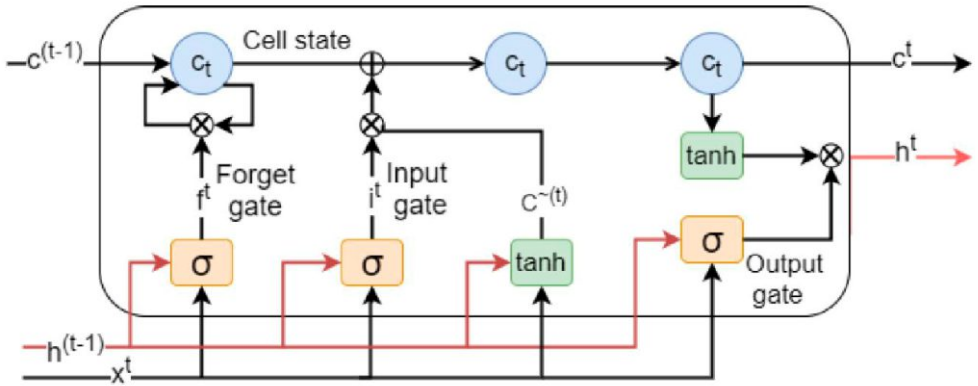


Figura 1. Componentes de una célula de una red LSTM

3.2 QLSTM

QLSTM es un algoritmo híbrido cuántico-clásico que utiliza VQC

en lugar de las puertas en una LSTM clásica y también dos funciones de activación, como se ve en la figura 2.




Figura 2. QLSTM

En QLSTM se reemplaza las compuertas de la red clásica por un circuito VQC, circuito variacional cuántico, que incluye los parámetros que serán optimizados mediante un algoritmo de QML que se aplica iterativamente. Para poder realizar el entrenamiento, se incluye una capa que codifica los datos en estados cuánticos, luego hay una capa variacional que se evalúa y se realiza la medición. A partir de estos resultados se ajustan los parámetros del VQC para lograr el aprendizaje.

4. Ingeniería de datos y características

Empresas Públicas de Medellín E.S.P., conocida por su acrónimo EPM, una empresa colombiana de servicios públicos proporcionó la base de datos utilizada. Tiene 2.765.004 registros divididos en 1.975 clientes totales en todo el departamento de Antioquia en 1.876 localidades. Estos clientes se dividieron en diferentes categorías como Residencial, Comercial, Industrial, Oficial, Especial y Auto Consumos EPM que pertenecen al mercado naciente de AGEP. La Tabla 1 resume las características del conjunto de datos. Los registros del medidor eléctrico, ACTIVA_IMP, van del 6 de junio de 2023 al 31 de julio de 2023. El 1,9% de los valores fueron NaN¹ o valores nulos. Esta variable se refiere a la

energía eléctrica consumida por un sistema o instalación, medida en kilovatios-hora (kWh). Es la energía total recibida de la red (importada) durante un período de tiempo con frecuencia horaria. La energía activa es la energía que realmente realiza un trabajo útil, como hacer funcionar la maquinaria, la iluminación, la calefacción, etc. Es la variable elegida para la predicción debido a la importancia del negocio.

Existen dos enfoques de pronóstico para los modelos LSTM (Long short-term memory) y QLSTM (Quantum Long Short-Term Memory): el primero solo tiene en cuenta la variable de pronóstico ACTIVA_IMP (la variable de pronóstico y) en términos de las horas, y el segundo modelo toma la variable de pronóstico ACTIVA_IMP, las variables más correlacionadas y las variables que tiene influencia en la variable de pronóstico según el experto en el negocio eléctrico. Las variables más correlacionadas se encontraron mediante un mapa de correlación descrito en la figura 3 que encuentra la correlación lineal entre variables con base en la ecuación del coeficiente de correlación de Pearson:

$$r_{xy} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}}$$

El rango de este coeficiente va de -1 a 1, donde $r=1$ indica una correlación positiva perfecta, $r=-1$ una correlación negativa perfecta y $r=0$ ninguna correlación lineal.

¹ NaN: Not a Number




Figura 3. Correlación lineal entre las variables del dataset entregado por EPM

A partir del mapa de correlación se identificaron las variables más correlacionadas como: V1, V2, V3, I1, I2, I3, REACTIVA_EXP y HORA. De estas, HORA se considera una variable exógena porque es un factor externo que influye en el sistema eléctrico, pero no es influenciado por él. Las variables restantes se consideran endógenas, ya que forman parte del sistema eléctrico que genera ACTIVA_IMP. Estas

variables se utilizaron para el enfoque descrito en las secciones 5.4 y 5.5. Los mejores hiper- parámetros para los modelos LSTM y QLSTM se seleccionaron utilizando una validación cruzada de series temporales con 3 pliegues, siguiendo múltiples divisiones de entrenamiento y prueba: 60% entrenamiento, 20% prueba, 70% entrenamiento, 20% prueba y 80% entrenamiento, 20% prueba. Después

de esto, se implementó un proceso de selección paso a paso, pero el mejor rendimiento del modelo se logró utilizando todas las variables mencionadas anteriormente.

Se tomaron los registros de los clientes de los últimos 16 días y se filtraron para eliminar los clientes con menos de 408 horas registradas, quedando 1,938 clientes.

Para cada experimento se normalizaron los datos utilizando standard scaler, tanto para el pronóstico con LSTM y como QLSTM. Las variables utilizadas para cada modelo se escalaron también con el método Min-Max y se convirtieron en el rango de [0, 1].

5. Resultados y Discusiones

Esta sección contiene los resultados obtenidos en este trabajo y las explicaciones de los dos enfoques desarrollados para el LSTM y el QLSTM mostrando los, resultados y conclusiones de los modelos.

5.1 Herramientas y enfoques utilizados para LSTM y QLSTM

Para este trabajo, los modelos clásicos se construyeron utilizando Python 3.11.5, las bibliotecas Pytorch para LSTM y QLSTM. Se utilizó Pennylane para la construcción de los circuitos VQC (Variational Quantum Circuit) y la arquitectura QLSTM basada en el repositorio de GitHub de Pennylane [17] y el estudio realizado sobre la predicción

del precio de las acciones utilizando BERT y GAN desarrollado en el repositorio de GitHub [18]. Hay dos enfoques utilizados para los modelos LSTM y QLSTM:

Enfoque 1: La variable ACTIVA_IMP es la única que se tiene en cuenta para los datos de entrenamiento $X_{training}$ y $Y_{training}$, y los datos de prueba X_{test} y Y_{test} siguiendo el enfoque de [19]. Este enfoque se utilizó solo para mostrar la independencia entre categorías en la sección 5.3 y la demostración de la mejor función de costo en la sección 5.2.

Enfoque 2: La variable de pronóstico y es la variable de pronóstico ACTIVA_IMP que tiene una relación de dependencia con las variables V1, V2, V3, I1, I2, I3, REACTIVA_EXP y HORA. Este enfoque se basa en [20].

5.2 Mejor función de Costo o Funcional: MSE vs MAE

Para demostrar cuál es la mejor función de costo o función de error, se realizó la predicción y el desempeño del modelo usando el cliente 18741848. Con este objetivo, se eligieron los siguientes hiper parámetros para los modelos LSTM (Tabla 3).

En la Figura 4, el rendimiento del modelo de pronóstico LSTM se evalúa utilizando funciones de costo MSE y MAE, lo que demuestra que la pérdida de entrenamiento

Hiperparámetro	Valor
División Entrenamiento/Prueba	80% entrenamiento, 20% prueba
Longitud de Secuencia (Entrenamiento)	10
Longitud de Secuencia (Prueba)	5
Tamaño de Entrada	1
Número de Capas	3
Tamaño Oculto	64
Tamaño de Salida	1
Tamaño del Lote	8
Número de Épocas	50
Pasos de Predicción	5
Tasa de Aprendizaje	0.0001
Número de Unidades Ocultas	16

Tabla 3 Hiperparámetros

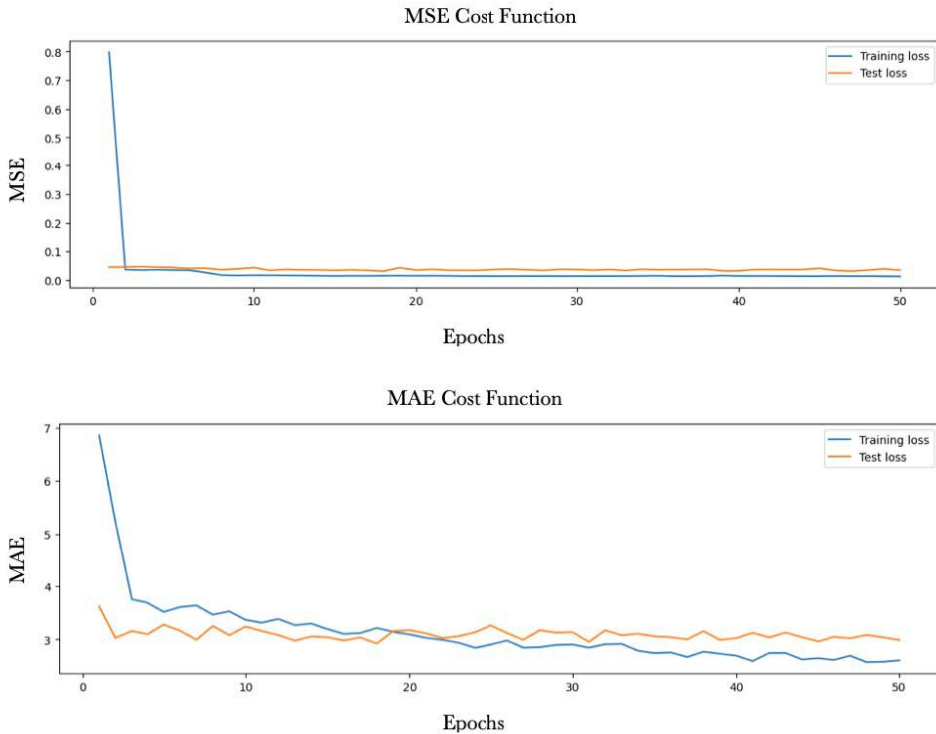


Figura 4. El rendimiento del modelo de pronóstico LSTM

disminuye con el tiempo, lo que indica optimización, y se mantiene consistentemente por debajo de la pérdida de prueba. MSE demuestra un rendimiento superior, con valores de pérdida de entrenamiento y prueba más bajos en comparación con MAE, que exhibe pérdidas significativamente más altas durante el entrenamiento. Muestra que la función de costo MSE tiene un mejor desempeño a medida que pasan las épocas de entrenamiento. A diferencia de la función de costo MAE (error absoluto medio), en la que podemos ver en la figura que, tanto la pérdida de entrenamiento como la pérdida de prueba, tienen valores mayores (valores enormes) en comparación con la función de costo MSE. Además, podemos ver que, para las primeras 20 épocas, la pérdida de prueba está por debajo de la pérdida de entrenamiento, lo que muestra un ajuste insuficiente, es decir, el modelo puede ser demasiado simple o no lo suficientemente complejo para capturar los patrones subyacentes en los datos de entrenamiento y puede que no esté aprendiendo de manera efectiva del conjunto de entrenamiento, lo que da como resultado una pérdida de prueba menor pero una pérdida de entrenamiento mayor.

En la Figura 5 se puede observar que para este cliente el mejor ajuste para los valores reales, KWh de las últimas 10 horas, es con la función de costo MSE que tiene un $R^2=0.9312$ y $MAPE = 0.075$ lo que

significa un 7.5 % para este último, lo cual es un porcentaje de error bastante bueno. Para la función de costo MAE obtuvimos un $R^2=0.68$ y $MAPE = 0.27$.

5.3 Independencia entre categorías utilizando LSTM

El objetivo de este trabajo es comparar el desempeño de los modelos LSTM y QLSTM. Para lograrlo es esencial desarrollar modelos basados en predicciones para clientes individuales (para intereses comerciales) así como para grupos de clientes. A continuación se verá que ciertas categorías exhiben baja correlación empleando una técnica analítica para el análisis de series de tiempo. Esta técnica utiliza datos de una categoría como conjunto de datos de entrenamiento y datos de otra categoría como conjunto de datos de prueba. Si ambos modelos para las categorías o subcategorías muestran un desempeño sólido en términos de la función de costo (que mide la optimización de errores) y las métricas utilizadas, como R^2 y MAPE, se puede concluir que existe una correlación entre estas categorías o subcategorías.

Para todas las pruebas realizadas para diferentes subcategorías se obtuvo un buen desempeño en términos de la función de pérdida de MSE. El primer caso fue para ambos clientes de la misma categoría 1-RESIDENCIAL y subcategoría 6-ESTRATO 6. Se pueden ver en

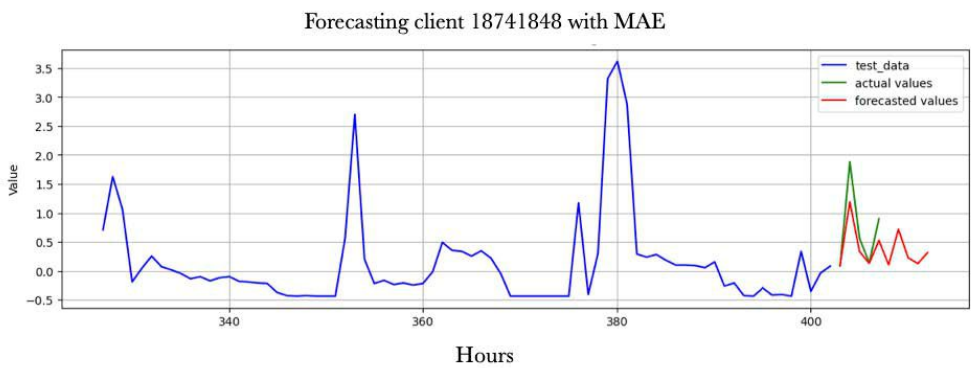
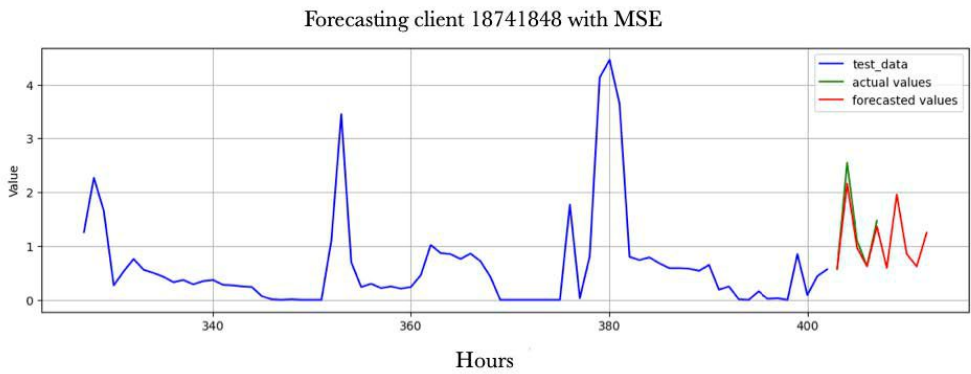


Figura 5. Pronóstico para el cliente 18741848 utilizando funciones de costo MSE y MAE.

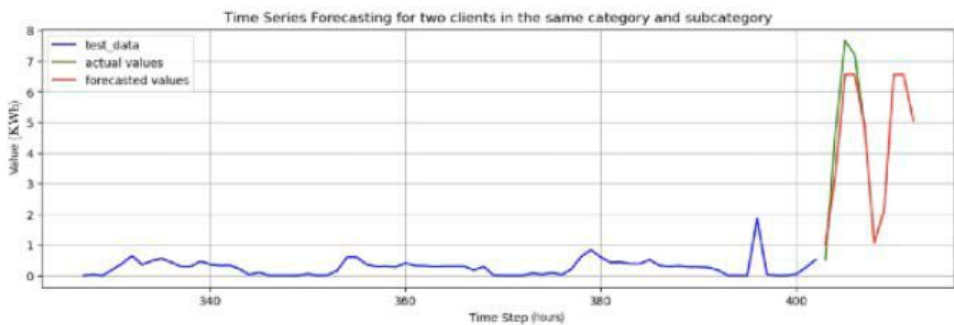


Figura 6. Pronóstico LSTM utilizando la función de costo MSE para dos clientes en la misma categoría y subcategoría

la Figura 6 los datos de entrenamiento y prueba y los valores de ACTIVA_IMP para las últimas 10 horas. Para este caso se tiene $R^2=0.8865$ y $MAPE= 0.3028472$, que son buenos resultados. Se puede inferir que los clientes de la misma subcategoría tienen un comportamiento de consumo de energía eléctrica similar.

Sin embargo, tomando dos clientes en diferentes subcategorías 6-ESTRATO 6 y 2- ESTRATO 2 los resultados son malos, como se ve en la Figura 7 con $R^2= -108.014921$ y $MAPE=0.3261$. Con un R^2 nega-

tivo podemos concluir una correlación inversa entre estos dos clientes.

La Figura 8 es la predicción del modelo LSTM con el conjunto de datos de entrenamiento para un cliente de la subcategoría 6-ESTRATO 6 y el conjunto de datos de prueba para un cliente de la categoría COMMERCIAL. Se observa una correlación incorrecta con $R^2=-2.16484$ y $MAPE=0.2104$.

La Figura 9 es la predicción del modelo LSTM con el conjunto de datos de entrenamiento para un cliente




Figura 7. Pronóstico LSTM utilizando la función de costo MSE para dos clientes en la misma categoría pero en diferentes subcategorías

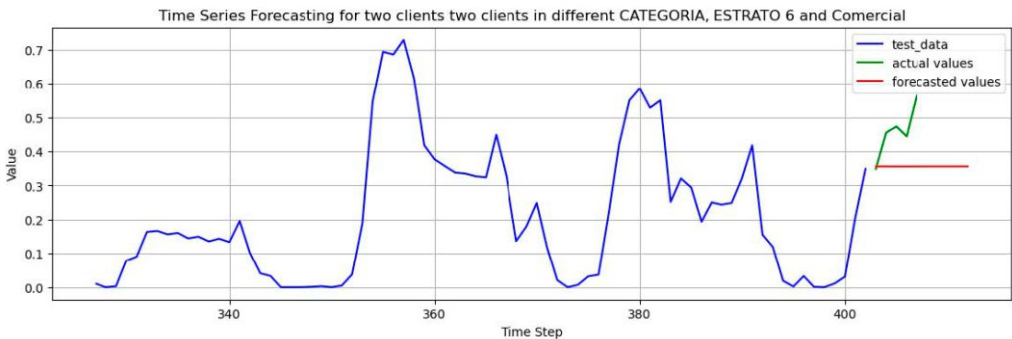


Figura 8. Pronóstico LSTM utilizando la función de costo MSE para dos clientes en diferentes categorías.




Figura 9. Pronóstico LSTM utilizando la función de costo MSE para dos clientes en la misma categoría, pero en diferentes subcategorías.

te de la subcategoría INDUSTRIAL y el conjunto de datos de prueba para un cliente de la categoría COMMERCIAL, 11-220V. Se observa una correlación deficiente con $R^2 = -4.4936$ y $MAPE = 0.3454$.

5.4 Predicción con un solo cliente: LSTM vs QLSTM

El modelo evaluado para LSTM y QLSTM fue para un cliente. El cliente 18741848 fue elegido utilizando el enfoque 2 en el que se eli-

gieron las variables más correlacionadas. Los dos modelos se tomaron con los mejores hiper parámetros descritos en la Tabla 4.

Además, los mejores hiper parámetros para la capa cuántica (hiper parámetros de los VQC) que fueron elegidos se exponen en la tabla 5.

Se trabajaron tres rotaciones de ángulos en la codificación para el embedding cuántico. La Figura 10




Figura 10. El rendimiento del modelo de pronóstico LSTM en términos de la función de costo MSE

Hiperparámetro	Valor
División Entrenamiento/Prueba	67% entrenamiento, 33% prueba
Longitud de Secuencia (Entrenamiento)	5
Longitud de Secuencia (Prueba)	5
Tamaño de Entrada	1
Número de Capas	4
Tamaño Oculto	52
Tamaño de Salida	1
Tamaño del Lote	1
Número de Épocas	50
Pasos de Predicción	5
Tasa de Aprendizaje	0.0001
Número de Unidades Ocultas	52

Tabla 4. Hiperparámetros

Hyperparámetro	Valor
Número de qubits	4
Rotaciones de ángulos	3
Capas cuánticas	4

Tabla 5. Hiperparámetros cuánticos

muestra el rendimiento del modelo LSTM en términos de la función de costo MSE. Las métricas de rendimiento para este modelo fueron $R^2=0,8580$ y "MAPE"= $0,1796$. El rendimiento del modelo de pronóstico LSTM en términos de la función de costo MSE muestra que la pérdida del tren a medida que las épocas avanzan en el tiempo obtiene valores más bajos, lo que muestra optimización (aprendizaje del algoritmo) y siempre está por debajo de la pérdida de prueba.

La Figura 11 muestra el desempeño del modelo QLSTM en términos de la función de costo MSE. Las métricas de desempeño para este modelo fueron $R^2=0.8585$ y MAPE= 0.2217 . En términos de la métrica de varianza, ambos modelos QLSTM y LSTM tienen los mismos resultados con los mejores hiper

parámetros, pero el modelo clásico gana con un 3% en la métrica de sesgo.

El rendimiento del modelo de pronóstico QLSTM en términos de la función de costo "MSE" muestra que a medida que las épocas avanzan la pérdida de entrenamiento obtiene valores más bajos, lo que muestra optimización (aprendizaje del algoritmo) y siempre está por debajo de la pérdida de prueba.

En la Figura 12 y la Figura 13 muestran la comparación entre LSTM y QLSTM en términos de pérdida de entrenamiento y prueba respectivamente. De la figura 15 es posible observar cómo el modelo de pronóstico QLSTM aprende más rápido que su contraparte clásica, en la




Figura 11. El rendimiento del modelo de pronóstico QLSTM

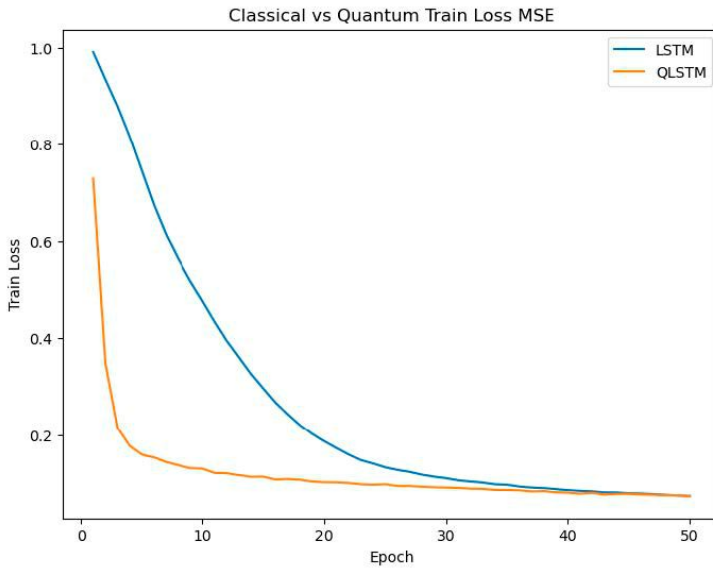


Figura 12. LSTM vs QLSTM en términos de pérdida de entrenamiento

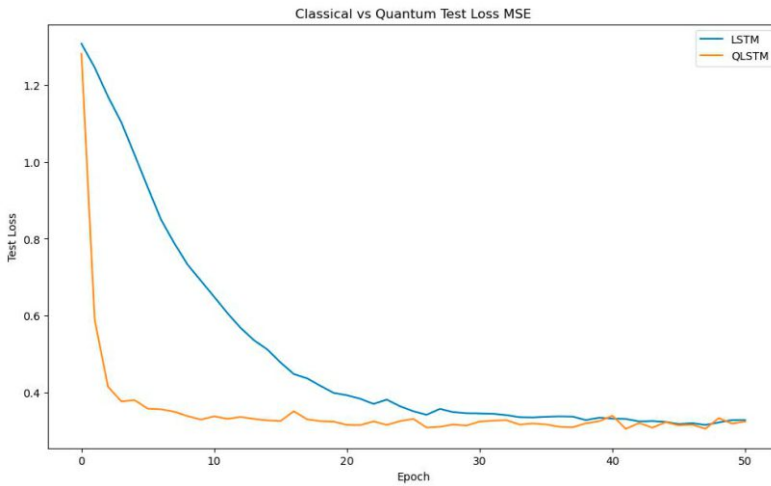


Figura 13. LSTM vs QLSTM en términos de la función de pérdida para los datos de prueba.

mitad de las épocas, aproximadamente en la época 25, la pérdida de entrenamiento tiene el mismo valor de la pérdida de entrenamiento del modelo LSTM en la época 50 demostrando cómo QLSTM, al utilizar el VQC muestra una mejor optimización en términos de la sintonización de ángulos (decidiendo qué parámetros olvidar y cuáles actualizar), que luego se utilizan en las funciones de activación de una infraestructura LSTM clásica.

En la Figura 12 se ve que el algoritmo híbrido QLSTM tiene el mismo valor de la función de pérdida de entrenamiento o función de costo MSE para los datos de entrenamiento en la mitad de las épocas.

Finalmente, la Figura 14 muestra el pronóstico para las 408 horas del

consumo del medidor eléctrico (KWh) del cliente 18741848, mostrando cómo tanto el modelo LSTM clásico como el modelo híbrido cuántico tienen un buen ajuste con respecto a los datos reales.

Es importante mencionar que el número de parámetros fueron 1553 y los parámetros del QLSTM fueron 228, mostrando cómo el QLSTM es más eficiente en términos de los parámetros que debe aprender.

5.5 Resumen de los Resultados Obtenidos

Luego de implementar los algoritmos y procesarlos en máquinas clásicas y máquinas cuánticas, se obtuvieron los siguientes resultados (Tabla 6).

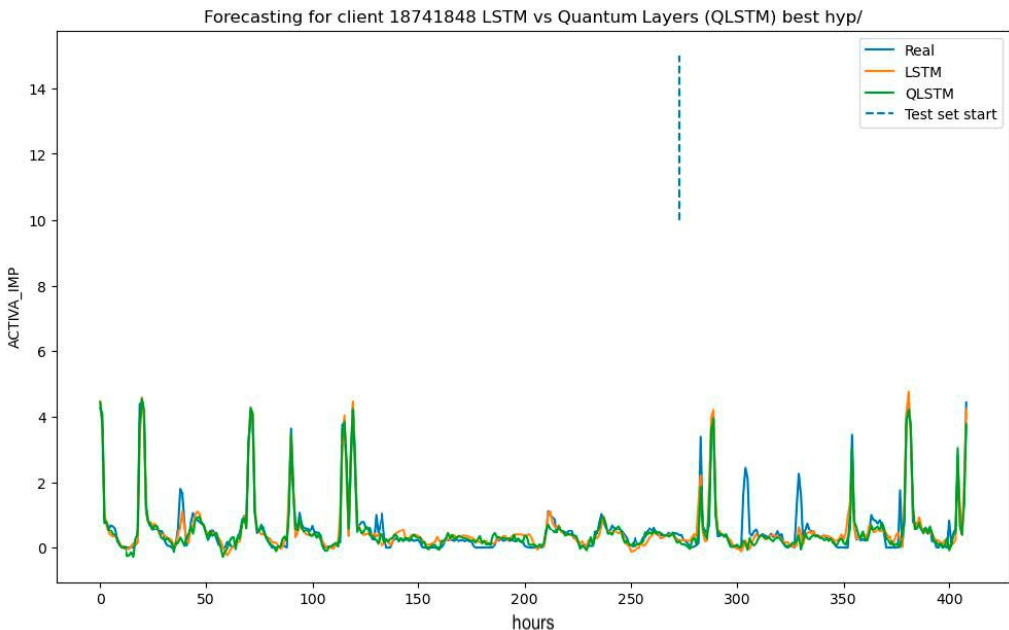


Figura 14. Predicción de ACTIVA_IMP para LSTM y QLSTM

Modelo y Tipo Computación	Características Físicas de las Máquinas Usadas	Datos Utilizados (cantidades y dimensionalidad)	Tiempo de Procesamiento promedio por época	Valores Métricas (R ² , MSE, MAPE)	Épocas	Época de convergencia
Predicción un cliente LSTM: Clásica	Máquina clásica.	Un cliente (cliente 18741848) Dimensionalidad: 408 filas Variables/columnas: 6 ['HORA', 'I1', 'I3', 'REACTIVA_EXP', 'V1', 'V3']	0.477 segundos	R ² : 0.845 MAPE: 0.240 MSE (última época): Train loss: 0.0821 Test loss: 0.345	50	49
Predicción un cliente LSTM: Cuántica	Simulación en máquina clásica.	408 filas cliente Dimensionalidad: Variables/columnas: 6 ['HORA', 'I1', 'I3', 'REACTIVA_EXP', 'V1', 'V3']	100.05 segundos	R ² : 0.846 MAPE: 0.244 MSE (última época): Train loss: 0.066 Test loss: 0.375	50	25
Predicción un cliente LSTM: Cuántica	Máquina cuántica real: IBM sherbrooke	408 filas cliente Dimensionalidad: Variables/columnas: 6 ['HORA', 'I1', 'I3', 'REACTIVA_EXP', 'V1', 'V3']	6 segundos	Por calcular	50	Por calcular

Tabla 6 Resultados

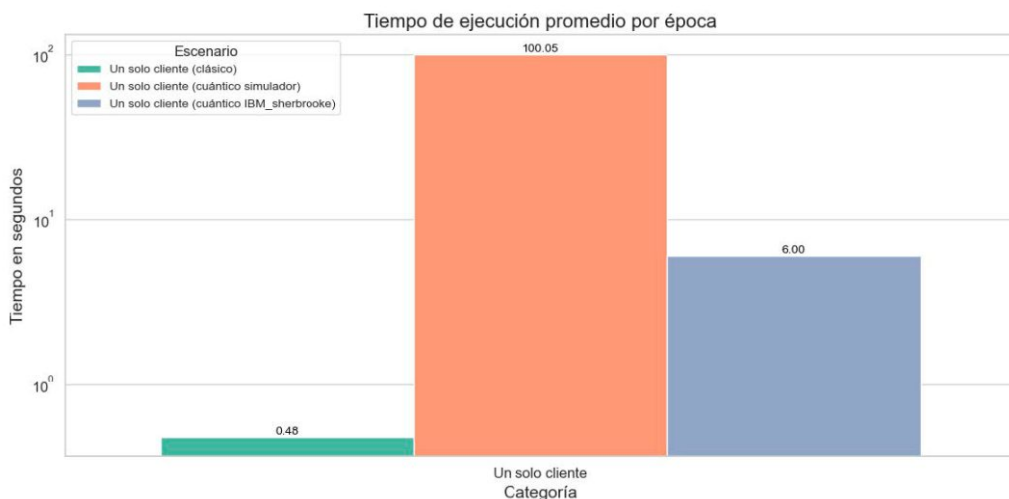


Figura 24 Tiempos de ejecución

Tiempo de ejecución vs tiempo en cola por época (máquina en IBM modelo para un cliente)

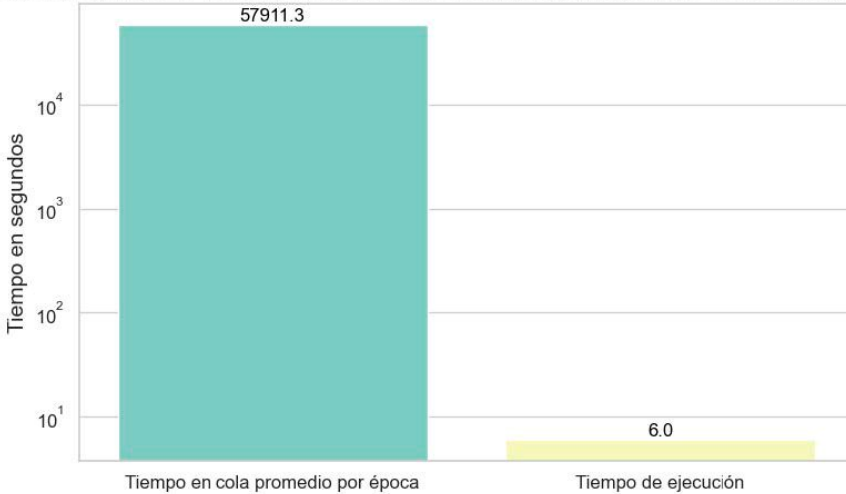


Figura 25 Tiempo de ejecución vs tiempo de espera en cola

6. Conclusiones

Durante la ejecución de esta fase del proyecto se generaron dos modelos, un modelo de aprendizaje de maquina clásico donde se implementó una red neuronal LSTM para el pronóstico de valores futuros en series de tiempo; un modelo híbrido donde se introdujeron capas de procesamiento cuántico de la información, este último se entrenó en simuladores de computación cuántica y en dispositivos cuánticos reales de IBM.

A partir de estos experimentos se llevó a las siguientes conclusiones:

- La computación cuántica abre nuevas posibilidades para pronosticar series de tiempo, al permitir obtener representaciones alternativas de procesamiento de la información.
- Los algoritmos implementados permitieron realizar pronósticos sobre las series de tiempo, produciendo resultados que se ajustan con los datos experimentales utilizados, en particular, se comprueba la pertinencia del uso de técnicas de aprendizaje de maquina cuántico para este problema de negocio.
- En los experimentos se evidencia que el algoritmo híbrido, que usa computación clásica y cuántica, converge más rápido que la alternativa clásica, necesitando menos iteraciones (épocas) para su entrenamiento, obteniendo indicadores de calidad que se comparan con los obtenidos por las técnicas clásicas.
- Es posible concluir entonces que el uso de la computación cuántica es viable técnicamente

y conduce, en algunos casos como el analizado en este experimento, a mejoras significativas en términos de eficiencia.

- Se evaluó la ejecución del algoritmo mediante simulación utilizando CPU, simulación utilizando GPU y máquinas cuánticas, analizando tiempos de ejecución, tiempos de acceso al recurso y costo de la ejecución, lo que permite concluir que la solución más viable desde el punto de vista del costo es utilizar simulación de dispositivos cuánticos empleando GPUs para realizar el entrenamiento y máquinas cuánticas para el pronóstico. De esta manera el sobre-tiempo para realizar el entrenamiento no impacta sobre los algoritmos de pronóstico desplegados para la inferencia de los datos, y beneficiándose de las tecnologías cuánticas.
- Evaluar el uso de diferentes proveedores de servicios cuánticos en la nube, reduciendo los sobretiempos de espera para el acceso a los dispositivos cuánticos.
- Evaluar estrategias alternativas en la configuración de las cargas de datos y la actualización de parámetros para facilitar el acceso oportuno a máquinas físicas.
- Evaluar otras aproximaciones, como por ejemplo redes totalmente conexas, que puedan mejorar la eficiencia o la calidad de las respuestas.

Adicionalmente, en el desarrollo del experimento se identificaron algunos frentes de trabajo futuro en donde se evidencia las posibles ventajas de la utilización de la computación cuántica en este problema, si bien existen dificultades técnicas para su implementación, estas alternativas son viables y deberían explorarse, ya que podrían conducir a posibles ventajas competitivas:

- Implementar un modelo de entrenamiento robusto empleando modelos de ruido de las maqui-

nas físicas, desplegando los modelos entrenados en ambientes con máquinas físicas para la inferencia y pronóstico de los datos.

- Evaluar el uso de diferentes proveedores de servicios cuánticos en la nube, reduciendo los sobretiempos de espera para el acceso a los dispositivos cuánticos.
- Evaluar estrategias alternativas en la configuración de las cargas de datos y la actualización de parámetros para facilitar el acceso oportuno a máquinas físicas.
- Evaluar otras aproximaciones, como por ejemplo redes totalmente conexas, que puedan mejorar la eficiencia o la calidad de las respuestas.

7. Referencias

- 1 H. K. Alfares y M. Nazeeruddin, «Electric Load Forecasting: Literature Survey and Classification of Methods,» *International Journal of Systems Science*, vol. 33, p. 3–34, 2002.
- 2 A. Khotanzad, E. Zhou y H. Elragal, «A Neuro-Fuzzy Approach to Short-Term Load Forecasting in a Price-Sensitive Environment,» *IEEE Transactions on Power Systems*, vol. 17, p. 1273–1282, 2006.
- 3 S. Arora y J. W. Taylor, «Rule-based autoregressive moving average models for forecasting load on special days: A case study for France,» *European Journal of Operational Research*, vol. 266, pp. 259-268, 2018.

- 4 S. Maldonado, A. González y S. Crone, «Automatic time series analysis for electric load forecasting via support vector regression,» *Applied Soft Computing*, vol. 83, p. 105616, 2019.
- 5 N. M. M. Bendaoud y N. Farah, «Using deep learning for short-term load forecasting,» *Neural Computing and Applications*, vol. 32, p. 15029–15041, 1 September 2020.
- 6 F. Javed, N. Arshad, F. Wallin, I. Vassileva y E. Dahlquist, «Forecasting for Demand Response in Smart Grids: An Analysis on Use of Anthropologic and Structural Data and Short Term Multiple Loads Forecasting,» *Applied Energy*, vol. 69, p. 15–160, 2012.
- 7 F. He, J. Zhou, Z.-k. Feng, G. Liu y Y. Yang, «A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm,» *Applied Energy*, vol. 237, pp. 103-116, 2019.
- 8 M. A. R. Biswas, M. D. Robinson y N. Fumo, «Prediction of residential building energy consumption: A neural network approach,» *Energy*, vol. 117, pp. 84-92, 2016.
- 9 K. Amarasinghe, D. L. Marino y M. Manic, «Deep Neural Networks for Energy Load Forecasting,» de *Proceedings of the 2017 IEEE 26th International Symposium on Industrial Electronics (ISIE)*, Edinburgh, 2017.
- 10 W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu y Y. Zhang, «Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network,» *IEEE Transactions on Smart Grid*, vol. 10, pp. 841-851, 2019.
- 11 M. Cerezo, G. Verdon, H. Y. Huang, L. Cincio y P. J. Coles, «Challenges and opportunities in quantum machine learning,» *Nat Comput Sci*, vol. 2, p. 567–576, September 2022.
- 12 D. Maheshwari, B. Garcia-Zapirain y D. Sierra-Sosa, «Quantum Machine Learning Applications in the Biomedical Domain: A Systematic Review,» *IEEE Access*, vol. 10, p. 80463–80484, 2022.
- 13 S. Y.-C. Chen, S. Yoo y Y.-L. L. Fang, «Quantum Long Short-Term Memory,» de *ICASSP 2022 - 2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2022.
- 14 Y. Yu, G. Hu, C. Liu, J. Xiong y Z. Wu, «Prediction of Solar Irradiance One Hour Ahead Based on Quantum Long Short-Term Memory Network,» *IEEE Transactions on Quantum Engineering*, vol. 4, pp. 1-15, 2023.
- 15 I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*, MIT Press, 2016.
- 16 C. C. Aggarwal, *Neural Networks and Deep Learning: A Textbook*, 1 ed., Springer Cham, 2018, pp. XXIII, 497.
- 17 R. Disipio, *QLSTM Implementation in PennyLane*, 2023.
- 18 D. Dulal, *Data Collection Notebook for SoftServe QLSTM*, 2023.
- 19 GeeksforGeeks, *Time Series Forecasting Using PyTorch*, 2023.
- 20 B. Kent, *How to use PyTorch LSTMs for time series regression*, 2021. 