

**PONTIFICIA UNIVERSIDAD
CATÓLICA DEL PERÚ**

Escuela de Posgrado



Rutas de evacuación por tsunami en La Punta, Callao,
mediante el uso de Reinforcement Learning

Tesis para obtener el grado académico de Maestro en Ingeniería
Civil con mención en Estructuras Sismorresistentes que presenta:

Joseph Diego Quispe Carpio

Asesor:

Luis Angel Moya Huallpa

Lima, 2024

INFORME DE SIMILITUD


Yo, Luis Angel Moya Huallpa, docente de la Escuela de Posgrado de la Pontificia Universidad Católica del Perú, asesor de la tesis titulada “Rutas de evacuación por tsunami en La Punta, Callao, mediante el uso de Reinforcement Learning”, del autor:

Joseph Diego Quispe Carpio

Dejo constancia lo siguiente:

- El mencionado documento tiene un índice de puntuación de similitud del 18%. Así lo consigna el reporte de similitud emitido por el software Turnitin el 14/05/2025.
- He revisado con detalle dicho reporte y la Tesis / el Trabajo de Investigación y no se advierte indicios de plagio.
- Las citas a otros autores y sus respectivas referencias cumplen con las pautas académicas.

Lugar y fecha: 27 de mayo del 2025

Apellidos y nombres del asesor: Moya Huallpa, Luis Ángel	Firma: 
DNI:43010087	
ORCID: 0000-0003-1764-3160	

Dedicatoria

A mi familia, en especial a mis padres por su apoyo incondicional durante la maestría y motivación para el desarrollo del presente trabajo.



Agradecimientos

A mi asesor Luis Moya, por las enseñanzas y constante apoyo durante el desarrollo del presente trabajo.

A la escuela de Posgrado de la PUCP por haberme permitido estudiar mi maestría y por todas las enseñanzas que me ayudaron en mi desarrollo profesional.

A mis compañeros de estudio de la escuela de Posgrado, por haberme apoyado en muchos de los cursos y por su motivación durante el desarrollo de esta tesis.


A PROCENCIA y a CONCYTEC, por su financiamiento en la elaboración del presente trabajo de investigación, en el marco del proyecto PE501078853-2022: Sistema inteligente de evacuación peatonal basado en técnicas de Reinforcement Learning.



Resumen

En los últimos años se ha realizado un estudio exhaustivo de los efectos de los tsunamis en los litorales de diversos países. Numerosas son las investigaciones que enfatizan la importancia de concientizar a la población para optimizar este proceso, salvando muchas vidas humanas. Por otro lado, el uso de la Inteligencia Artificial (IA) ha cobrado protagonismo en los últimos años, resolviendo muchos problemas ingenieriles, automatizando procesos. Reinforcement Learning (RL) es una aplicación de IA en la que un agente “refuerza” su comportamiento para obtener un valor óptimo, teniendo como base el ensayo y error.

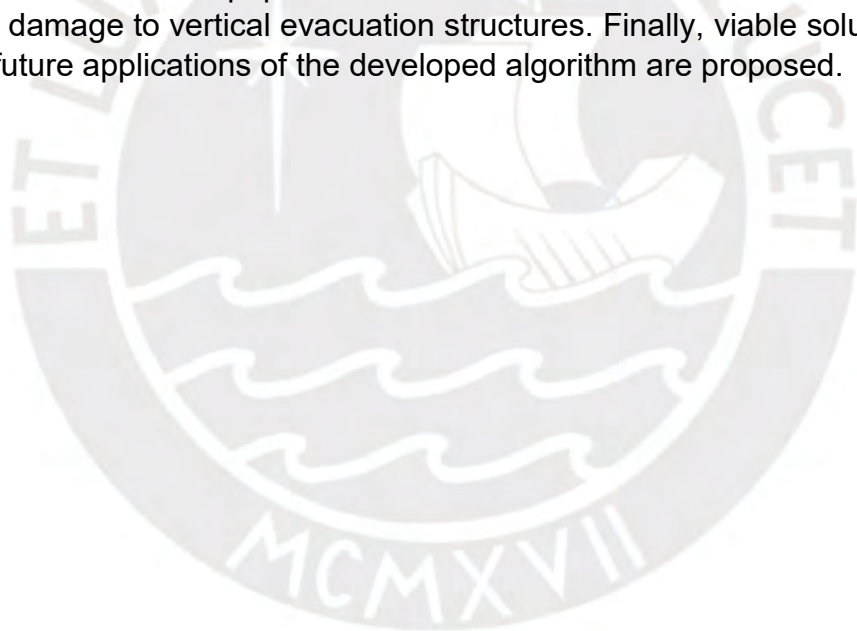
El distrito de la Punta, Perú, por su ubicación geográfica, es muy vulnerable frente a tsunamis, dado que podría estar completamente afectada por un tsunami, por lo que resulta de vital importancia obtener rutas óptimas de evacuación para reducir el riesgo de desastre. La presente investigación hace uso de un algoritmo de RL, donde se evalúa el comportamiento de un peatón y su toma de decisiones frente a un tsunami, en un modelo de la zona inundable de la Punta, mediante simulaciones computacionales para obtener rutas óptimas de evacuación frente a un tsunami. El algoritmo logra optimizar el proceso de evacuación peatonal, determinando datos cuantificables del número de personas que lograrían evacuar en un tiempo de 30 minutos, concluyendo que solo el 50 por ciento de la población del distrito lograría evacuar en un escenario que considere el daño de las estructuras de evacuación vertical. Finalmente, se proponen posibles alternativas de solución viables y las posibles aplicaciones a futuro del algoritmo desarrollado.



Abstract

In recent years, an exhaustive research has been conducted on the effects of tsunamis on the coastlines of various countries. Numerous studies emphasize the importance of raising public awareness to optimize this process, saving many lives. Furthermore, the use of Artificial Intelligence (AI) has gained prominence in recent years, solving many engineering problems and automating processes. Reinforcement Learning (RL) is an AI application in which an agent "reinforces" its behavior to obtain an optimal value, based on trial and error.

Due to its geographical location, the district of La Punta, Peru, is highly vulnerable to tsunamis, as it could be completely affected by a tsunami. Therefore, it is vitally important to establish optimal evacuation routes to reduce the risk of disaster. This research uses a real-time real-time RL algorithm to evaluate pedestrian behavior and decision-making in the face of a tsunami in a model of the Punta floodplain. This algorithm uses computational simulations to obtain optimal evacuation routes in the event of a tsunami. The algorithm optimizes the pedestrian evacuation process by determining quantifiable data on the number of people who would be able to evacuate within 30 minutes. It concludes that only 50 percent of the district's population would be able to evacuate in a scenario that considers damage to vertical evacuation structures. Finally, viable solutions and potential future applications of the developed algorithm are proposed.



Índice

INTRODUCCIÓN	1
CAPITULO I: GENERALIDADES	2
1.1. PLANTEAMIENTO DEL PROBLEMA	2
1.2 OBJETIVOS	4
1.3 ALCANCES	4
CAPÍTULO II: ESTADO DEL ARTE	5
2.1 MITIGACIÓN DE RIESGOS FRENTE A TSUNAMIS	5
2.2 LA IA EN LA REDUCCIÓN DE RIESGOS FRENTE A DESASTRES	8
2.3 LOS RETOS DE LA INTELIGENCIA ARTIFICIAL FRENTE A LA RRD.....	9
2.4 REINFORCEMENT LEARNING Y SU APLICACIÓN PARA EVACUACIÓN PEATONAL ..	10
CAPÍTULO III: MARCO TEÓRICO	14
3.1 ALGORITMO FUNDAMENTAL DEL REINFORCEMENT LEARNING	14
3.1.1 <i>El proceso de decisión de Markov</i>	14
3.1.2 <i>La política del agente</i>	14
3.1.3 <i>Exploración y explotación</i>	15
3.2 TEMPORAL DIFFERENCE LEARNING	15
3.3 CURVAS DE FRAGILIDAD	16
CAPÍTULO IV: APLICACIÓN DEL REINFORCEMENT LEARNING A LA EVACUACIÓN PEATONAL	17
4.1 MODELAMIENTO DEL ENTORNO	17
4.2 ALGORITMO DE REINFORCEMENT LEARNING DEL MODELO.....	22
4.3 HIPÓTESIS DEL PROCESO DE EVACUACIÓN	25
CAPÍTULO V: SIMULACIONES NUMÉRICAS	27
5.1 SIMULACIONES EN LA ZONA INUNDABLE DEL CALLAO.....	27
5.2 ESCENARIO SÍSMICO FRENTE A UN TSUNAMI EN EL DISTRITO DE LA PUNTA.....	32
CONCLUSIONES	41
RECOMENDACIONES	43
BIBLIOGRAFÍA	44

Lista de figuras

Figura 2. Mapa de acoplamiento sísmico.(INDECI, 2017)	3
Figura 3. Mapa de vulnerabilidad frente a tsunamis en la ciudad de Lima.(CENEPRED, 2017)	3
Figura 4. Tráfico vehicular en el distrito del Callao en horas punta.	4
Figura 5. Tráfico vehicular debido a alerta de tsunami en Banda Aceh, Indonesia, 2012.	6
Figura 6. Estado de edificio en las partes altas post-tsunami. (JICA, 2011)	6
Figura 7. Estructuras de evacuación vertical recomendadas por FEMA	7
Figura 8. Aplicación de la IA a la RRD entre los años 2018 – 2022. (Kuglitsch et al., 2022)	9
Figura 9. Ciclo de vida de la IA aplicada a la RRD. (León, Zamora, et al., (2019)	10
Figura 10. Problema de la ruta más corta. (García Avellaneda, 2019).....	12
Figura 11. Simulación de movimiento peatonal frente a un tsunami (E Mas et al., (2020).....	13
Figura 12. Algoritmo fundamental del RL. (Sutton & Barto, 2014).....	15
Figura 13. Actualización del valor en el método de MC vs TDL. (Sutton & Barto, 2014)	¡Error! Marcador no definido.
Figura 14. Ejemplo de curva de fragilidad. (Blondet & Velásquez, 2005).....	16
Figura 15. Modelo de un entorno conformado por nodos, links, peatón y nodo de evacuación.	17
Figura 16. Mapa de inundación frente a un tsunami en el Callao.....	19
Figura 17. Modelo de Líneas de la zona inundable del Callao	19
Figura 18. Estructuras para evacuación vertical.(Mas et al., 2012).....	20
Figura 19. Modelo de la zona inundable y puntos de evacuación de La Punta	21
Figura 20. Cálculo de la población del área de estudio.....	21
Figura 21. Asignación de puntaje por tipo de nodo.	23
Figura 22. Diagrama de flujo del algoritmo del RL del modelo generado. (Erick Mas et al., 2024).....	23
Figura 23. Altura del Tsunami para un evento sísmico de 9.0 Mw en La Punta, Callao vs el tiempo.	26
Figura 24. Patrón de movimiento peatonal en un instante de tiempo arbitrario.	28
Figura 25. Proceso de evacuación de peatones empleando el sistema guía durante el minuto 23.....	29
Figura 26. Gráfico del incremento de número de evacuados vs número de simulaciones.....	30
Figura 27. Congestión peatonal en distintos instantes de tiempo.	31
Figura 28. Zonas de mayor congestión peatonal frente a una evacuación por tsunami.....	32
Figura 29. Modelo del entorno del distrito de la Punta.	33
Figura 30. Gráfico comparativo de la población evacuada en cada simulación y en la ruta más corta.....	33
Figura 31. Simulaciones numéricas distrito de la Punta.....	34

Figura 32. Mapa de Pseudoaceleraciones para un período de $T=1$ seg. en la zona de La Punta. (Pulido et al., 2015). 36

Figura 33. Determinación de la probabilidad de excedencia de un estado de daño de los edificios de evacuación vertical. (Villar-Vega et al., 2017). 37

Figura 34. Modelo del entorno de la Punta, considerando daño de estructuras de evacuación vertical. 37

Figura 35. Simulaciones numéricas distrito de la Punta, considerando daño de edificios de evacuación vertical. 39

Figura 36. Número de personas evacuadas por cada simulación vs la ruta óptima. Caso con daño de edificios de evacuación vertical. 39

Figura 37. Número de evacuados versus tiempo en el distrito de la Punta. 40



Introducción

Los tsunamis son una serie de ondas de agua producidas por una perturbación en el océano, la mayoría de las veces por un terremoto, que se mueve a través del océano a grandes velocidades y puede causar daños significativos y pérdida de vidas humanas en las áreas costeras. Se han realizado simulaciones en el distrito de La Punta, Callao, en las que se concluyó que, un terremoto de 8.5Mw frente a las costas del Callao, provocaría una inundación de 12 a 15 metros de profundidad con olas de hasta 10 metros de altura, en un tiempo de aproximadamente 30 minutos luego de ocurrido el sismo.(CISMID & UNI, 2010). Luego de ocurrido un evento sísmico, existe un lapso en el que se forman los tsunamis, que puede durar desde minutos hasta horas. Este tiempo debería ser aprovechado por la población en peligro para realizar la evacuación de la zona en riesgo, a una zona segura. Sin embargo, se han evidenciado procesos de evacuación ineficientes, en muchas importantes ciudades en el mundo, debido a factores como el pánico de la población, donde se ha observado que muchos pobladores utilizan sus vehículos para realizar la evacuación, generando congestiones vehiculares que retrasan el tiempo de evacuación y reducen las probabilidades de supervivencia (Mas et al., 2020), como se observó en una alerta de tsunami en 2018 en Banda Aceh, Indonesia. Asimismo, si incluimos otros factores como la alta densidad poblacional, la deficiente distribución de calles que puedan ser utilizadas como rutas de evacuación, y el tráfico que presenta la ciudad de Lima en horas de mayor afluencia, el problema de evacuación se vuelve más complejo, lo que podría llegar a consecuencias muy lamentables, con numerosas pérdidas humanas.

Desarrollar una ruta óptima de planificación de rutas para peatones considerando la dinámica de aprendizaje y las incertidumbres en el entorno constituye un gran desafío (Park et al., 2022) para la comunidad ingenieril, debido a la complejidad y cantidad de variables del problema. Ante esto, en los últimos años el uso de la Inteligencia Artificial se ha desarrollado a un nivel notable (Zhang et al., 2021), cobrando protagonismo en la solución de problemas de ingeniería, automatizando procesos y optimizando soluciones. (Mas et al., 2020) desarrollaron simulaciones de evacuación peatonal ante tsunamis en un entorno urbano, aplicando y calibrando modelos de aprendizaje por reforzamiento, lo que permitió incrementar progresivamente el número de personas evacuadas con éxito. La presente investigación, retoma dicha metodología con el objetivo de aplicarla a un caso específico: el distrito de La Punta, Callao, a fin de evaluar su efectividad en un contexto local.

CAPITULO I: Generalidades

1.1. Planteamiento del problema

Nuestro país, por ubicarse dentro del Cinturón de Fuego del Pacífico, es altamente sísmico. Por otro lado, la costa central del Perú, en particular el área frente a Lima y Callao, podría estar atravesando un fenómeno conocido como Silencio Sísmico. Es así que, el instituto Geofísico del Perú (IGP) ha desarrollado una metodología que permite monitorear los movimientos de la superficie. Dichos movimientos están directamente asociados al proceso de acumulación de energía y deformación que se produce en la zona de contacto de las placas tectónicas y que se propagan a la superficie de la corteza terrestre. Al medir la deformación de la superficie terrestre con GPS se puede identificar las zonas que acumulan energía sísmica y que darán lugar a los futuros terremotos. Las zonas de acumulación de este tipo de energía se les conoce como zonas de acoplamiento sísmico (INDECI, 2017).

El informe del Escenario Sísmico para Lima Metropolitana y Callao (INDECI, 2017), menciona que la zona acoplada en nuestro país con mayor dimensión se ubica frente a la costa de la región central de Perú. Esta zona abarcaría una longitud de 470 km, la cual, de liberar toda la energía sísmica acumulada hasta la fecha, podría generar un sismo de magnitud entre 8.6 - 8.8Mw (Figura 1).

Adicional a ello estudio elaborado por CENEPRED (2017), determinó que las zonas inundables frente a tsunamis generados por sismos de 8.5 Mw y 9.0 Mw, en Lima Metropolitana (Figura 2). De esta forma se puede tener las posibles zonas en que la población presenta mayor peligro frente a este fenómeno natural.




Figura 1. Mapa de acoplamiento sísmico.(INDECI, 2017)



Figura 2. Mapa de vulnerabilidad frente a tsunamis en la ciudad de Lima.(CENEPRED, 2017)

La ciudad de Lima presenta a diario grandes problemas con el tráfico vehicular, (Figura 3), ocupando el primer lugar en América Latina, de acuerdo con un estudio del servicio especializado en tecnologías de geolocalización, TomTom Traffic. Según el Índice de tráfico de 2023, en Lima se necesita un promedio de 28 minutos y 30 segundos para recorrer 10 kilómetros. Dicho problema impediría el desarrollo adecuado de un proceso de evacuación frente a una emergencia. Y si a ello le añadimos la falta de cultura de prevención de la población frente a estos eventos, y la gran densidad poblacional de la ciudad. Todo ello podría llevar a un escenario catastrófico frente a un tsunami, con la pérdida de muchas vidas humanas.

Ante esta problemática, la investigación en desarrollo busca mitigar los riesgos que este desastre natural podría causar en la zona costera del Callao, mediante un método que permita optimizar el proceso de evacuación peatonal, a través de algoritmos de aprendizaje por reforzamiento.

1.2 Objetivos

Objetivo general

Establecer rutas de evacuación frente a un tsunami en La Punta, Callao usando Reinforcement Learning

Objetivos Específicos

- Representar la red vial y peatonal de la zona de estudio mediante un modelo.
- Cuantificar el desempeño del peatón durante la evacuación mediante una función de recompensa.
- Obtener un modelo optimizado mediante iteraciones.



Figura 3. Tráfico vehicular en el distrito del Callao en horas punta.

Fuente: <https://elcomercio.pe/peru/callao-caos-vehicular-avenida-faucett-imagenes-417199-noticia/>

1.3 Alcances

Se realizarán simulaciones numéricas por computador, en un entorno virtual, en donde se aplicarán algoritmos de Reinforcement Learning para obtener rutas de evacuación óptimas frente a un tsunami en la ciudad de Lima, en donde se intervendrán las variables que influyen en la toma de decisiones de un peatón. Las simulaciones se realizarán mediante el lenguaje de programación Python.

CAPÍTULO II: Estado del arte

En la presente sección se desarrollará una revisión exhaustiva de los avances en la aplicación de las medidas de mitigación de riesgos frente a tsunamis, y como se ha aplicado el aprendizaje por reforzamiento en sistemas inteligentes de evacuación peatonal, con un enfoque particular en su aplicación ante escenarios de riesgo natural como los tsunamis, con el objetivo de ofrecer un panorama claro sobre cómo se ha abordado el problema a lo largo de los años y como el uso de algoritmos de aprendizaje por reforzamiento se presenta como una alternativa de solución.

2.1 Mitigación de riesgos frente a tsunamis

En el año 2004 ocurrió en Indonesia, un terremoto de Mw 9.0 que posteriormente provocó un tsunami, que ocasionó cerca de 230 mil muertes en 14 países (IFRC, 2009), siendo uno de los mayores desastres de la historia. Es así, que se incrementaron los esfuerzos a nivel internacional para mitigar los riesgos frente a este desastre natural, destacando principalmente las estrategias de planificación, mitigación y prevención frente a tsunamis en países como Estados Unidos, Chile y Japón. Por ejemplo, Esteban et al., (2013), analiza el impacto de tsunamis en Chile e Indonesia, los países con mayor registro de tsunamis en el mundo, mediante encuestas a los habitantes de las zonas previamente golpeadas por este fenómeno natural. De dichas encuestas se encontró que la población realiza la evacuación en su mayoría de veces cuando se observa un comportamiento anómalo del mar, por aviso de los vecinos, o incluso después que llega la primera ola del tsunami. También se pudo encontrar que gran parte de la población en Chile realizó la evacuación con auto, mientras que en Indonesia se realizó caminando. Abarca & Lizana, (2020) destacan la importancia de la educación de la población frente a eventuales tsunamis en Chile, el cual no está siendo tomado en cuenta en las estrategias de prevención de riesgos. Adicional a ello, en el año 2010, en Chile, se evidenció un deficiente sistema de alerta de tsunami. La Oficina Nacional de Emergencia del Ministerio del Interior (ONEMI) no emitió una alerta de tsunami efectiva para la población, a pesar de que el Servicio Hidrográfico y Oceanográfico de la Armada (SHOA) habían enviado una advertencia inicial, contribuyendo a que una gran cantidad de personas no evacuaran a tiempo de la zona costera.

Un ejemplo de evacuación deficiente se observó durante la alerta de tsunami en Banda Aceh, Indonesia, en 2012, en la misma región afectada por el devastador tsunami de 2004. Ante la alerta, la población, en su mayoría presa del pánico y con escasa preparación para este tipo de emergencias, provocó congestión vehicular masiva (Figura 4). Esta experiencia evidenció la falta de educación y protocolos adecuados para una respuesta eficaz frente a desastres.



Figura 4. Tráfico vehicular debido a alerta de tsunami en Banda Aceh, Indonesia, 2012.

Fuente: Terremoto en Indonesia hizo saltar alarmas de tsunami en el Índico”, por RPP Noticias, 11 de abril de 2012 (<https://rpp.pe/lima/actualidad/terremoto-en-indonesia-hizo-saltar-alarmas-de-tsunami-en-el-indico-noticia-470589>)



Figura 5. Estado de edificio en las partes altas post-tsunami. (JICA, 2011)

En estos casos la población opta por utilizar la evacuación horizontal, para mantenerse alejado de la zona de inundación, esta práctica se ha observado en muchas de las experiencias pasadas. Sin embargo, en los últimos años se ha mencionado la evacuación vertical como una alternativa eficiente en la evacuación peatonal frente a tsunamis. Mas et al., (2012) menciona la importancia de las estructuras de evacuación vertical como alternativa de evacuación frente a tsunamis, tomando como referencia el tsunami ocurrido en Japón, en el año 2011, en el que se salvó un gran número de vidas debido a la evacuación vertical, pues las partes altas de los edificios no son alcanzadas por los tsunamis, como se observa en la Figura 5. Esta experiencia demuestra que una infraestructura resistente fortalece la resiliencia frente a desastres, bajo el enfoque de “construir mejor”, Maly & Suppasri (2020). Es decir, considerar la construcción de infraestructura resistente de evacuación vertical representa la adaptación de la sociedad ante una amenaza por tsunami




Figura 6. Estructuras de evacuación vertical recomendadas por FEMA

(a) Torre para evacuación vertical recomendada por FEMA (2008). (b) Cerro artificial para evacuación en Japón. (León, Zamora, et al., 2019)

Adicional a esto, los resultados de León et al., (2019), indican que en la ciudad chilena de Viña del Mar, más del 38% de la población no alcanzaría alejarse de la zona inundable en un rango de 20 minutos, ello evidencia una necesidad prevalente de establecer puntos de evacuación vertical frente a un tsunami. La alternativa de la evacuación vertical frente a tsunamis ya ha sido abordada en tres países con una alta incidencia de tsunamis: Japón, Estados Unidos e Indonesia, en donde existen lineamientos específicos para el diseño de estructuras de evacuación vertical (Figura 6).

En nuestro país, el INDECI en conjunto con el IGP, la Marina de guerra del Perú, y el Centro Nacional de Alerta frente a Tsunami (CNAT) desarrollaron en el año 2014 cartas de inundación en la costa peruana, la cual indica la zona inundable de algunos distritos del país frente a un eventual tsunami post sismo de magnitudes Mw 8.5 y Mw 9.0. Asimismo en el año 2021, se establecieron lineamientos para el diseño de estructuras para evacuación vertical frente a tsunamis (Carranza, (2021). Del mismo modo, se tienen identificadas 20 estructuras para evacuación vertical en el distrito de la Punta. Diversos estudios recientes han demostrado la importancia de considerar el comportamiento estructural de edificaciones destinadas a la evacuación vertical frente a tsunamis. Un caso es el de (Petrone et al., 2020), quienes evaluaron la fragilidad de estructuras de concreto armado bajo acciones de tsunami, tanto de manera aislada como en secuencia con sismos previos, identificando que, si bien el daño sísmico puede afectar su desempeño, la influencia en la capacidad estructural ante tsunamis puede ser moderada.

2.2 La IA en la Reducción de Riesgos frente a desastres

La Inteligencia Artificial (IA) es una rama de la informática que logra que las computadoras puedan realizar tareas como los humanos, es decir, que puedan pensar, percibir, representar y dar soluciones a distintos problemas de la sociedad. La IA tiene diversas aplicaciones en el campo de la ingeniería y en la industria en general, tales como automatización, digitalización, robótica, incremento de productividad, y mitigación de riesgos. Mediante el uso de simulaciones y modelos probabilísticos se puede analizar múltiples escenarios frente a un posible desastre natural, con el objetivo de preparar a la población vulnerable frente a dichos eventos naturales.

El uso de herramientas digitales en la ingeniería en general ha experimentado un auge a nivel mundial, debido al rápido avance de la tecnología y la búsqueda de incrementar la eficiencia de procesos automáticos, por lo que el uso de la IA se ha venido incrementando considerablemente en los últimos años. Kuglitsch et al., (2022) realizan un estudio de documentación reciente entre los años 2018 y 2021, de los enfoques de aprendizaje automático que se están aplicando en los últimos años para la Reducción de Riesgos frente a desastres naturales (RRD) (Figura 7).

Un claro ejemplo de cómo la IA aplicada a la RRD, es la detección de tsunamis. Hace diez años cuando las costas de Japón fueron golpeadas por el tsunami de Tohoku, se tardó varios días en comprender la totalidad del desastre. Es entonces que el grupo Geodesy4Sendai, colabora con la implementación de alertas tempranas frente a tsunamis, en una acción conjunta con la Unión Internacional de Telecomunicaciones (UIT), la Organización Meteorológica Mundial (OMM) y el Grupo focal sobre inteligencia artificial aplicada a la gestión de desastres naturales del Programa de las Naciones Unidas para el Medio Ambiente (PNUMA). Lo que se busca que es el procesamiento de datos en tiempo real del Sistema mundial de navegación por satélite (GNSS), para poder facilitar la transmisión de información a la población frente a un eventual tsunami y salvar el mayor número de vidas.

En nuestro país, una de las aplicaciones recientes de la IA para la RRD es de Guilherme & Viviane, (2023). Dicho estudio, basado en datos del Instituto Geofísico del Perú (IGP), emplea información de monitoreo del volcán Sabancaya, ubicado en Arequipa, Perú, con el objetivo de contribuir a la sepredicción del nivel de alerta ante su actividad volcánica. Podemos decir en líneas generales que en nuestro país aún no es de amplia difusión el uso de la IA para sistemas de alerta temprana frente a desastres.

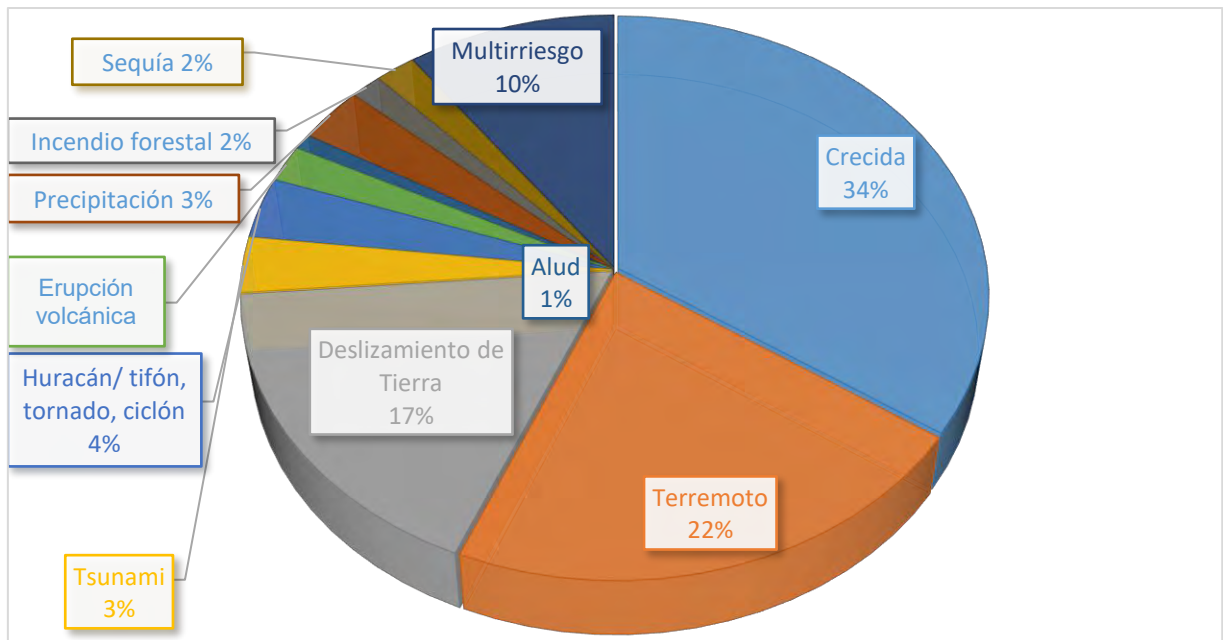


Figura 7. Aplicación de la IA a la RRD entre los años 2018 – 2022. (Kuglitsch et al., 2022)

2.3 Los retos de la Inteligencia Artificial frente a la RRD

Cuando se aplica la IA a la RRD se puede plantear un ciclo de vida, como se observa en la Figura 8. Y como en todo ciclo de vida, se pueden presentar algunos problemas. Durante la recopilación de datos es importante tener en cuenta el sesgo que se puede generar durante la obtención y tratamiento de datos. Es decir, si la IA se aplica en datos con patrones que nunca se observó durante el proceso de calibración, los resultados no serán precisos. Para poder obtener algoritmos confiables se necesitan fuertes alianzas entre países y libertad al acceso de información para su posterior procesamiento.

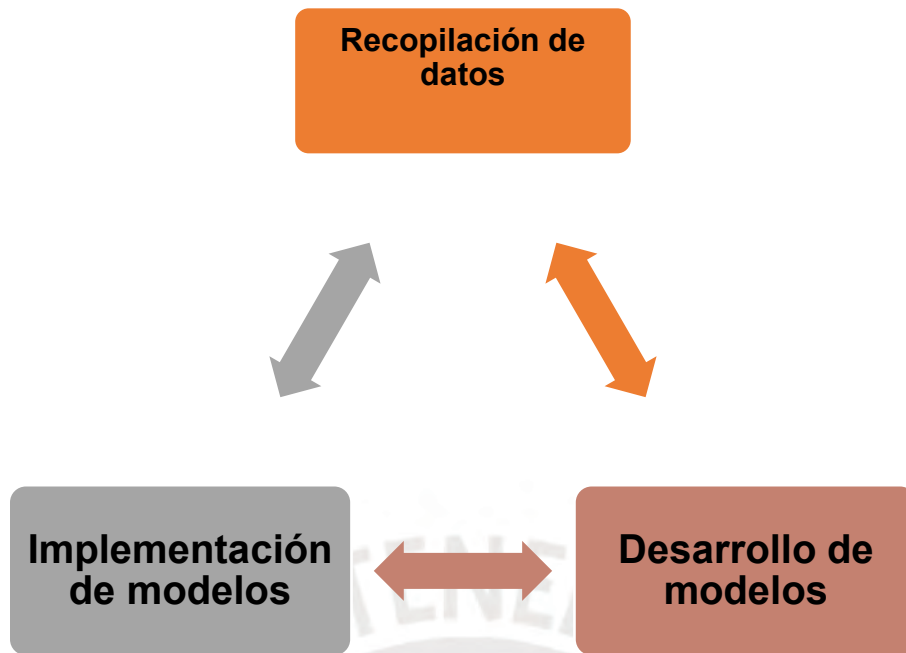


Figura 8. Ciclo de vida de la IA aplicada a la RRD. (León, Zamora, et al., (2019)

En la etapa del desarrollo de modelos es importante considerar el costo computacional del aprendizaje del modelo a desarrollar, debido a que los modelos más precisos requieren un alto costo computacional, con máquinas capaces de correr algoritmos complejos, ya que el fenómeno resulta muy complejo. Estos modelos también deben ser capaces de obtener resultados que sean comprensibles para toda la población objetivo.

Un modelo evaluado correctamente, con una buena precisión de resultados, y el cual ha sido consensuado entre los gestores del proyecto y las autoridades pertinentes está listo para ser implementado como herramienta para la RRD. Esta etapa puede requerir una retroalimentación en caso no se llegue a un consenso.

2.4 Reinforcement Learning y su aplicación para evacuación peatonal

La evacuación de emergencia es una compleja situación donde decisiones críticas deben ser tomadas bajo situaciones de extrema presión de tiempo, en donde se pueden salvar muchas vidas humanas si se toman las decisiones adecuadas (Yang et al., (2022). Por otro lado, Reinforcement Learning es un paradigma del aprendizaje que logra resolver una cadena de decisiones secuenciales para resolver un problema, mediante la interacción de un agente con su entorno, con lo cual dicho agente “refuerza” su aprendizaje a través de dicha interacción (Sutton & Barto, (2014). Es así que, los últimos años, se ha propuesto el uso del RL para resolver problemas rutas de evacuación, realizando simulaciones en la que un agente recorre por muchos caminos, hasta encontrar la ruta más corta. Wang et al., (2016), presenta una simulación de evacuación multimodal para un tsunami, donde evalúa las variables que intervienen durante el proceso de evacuación y como cada una de ellas afectan en la mortalidad de este desastre. Finalmente, encuentra que el tiempo de toma de decisiones del peatón y las variaciones en las tomas de decisiones influyen muy fuertemente

en la tasa de mortalidad frente al tsunami. Sharma et al., (2019) utilizan algoritmos Q-learning para realizar una simulación de evacuación en una edificación frente a un incendio. En este caso, el entorno se modela como la estructura del edificio, y las condiciones que afectan el comportamiento del agente incluyen la propagación del fuego, la presencia de cuellos de botella y la incertidumbre. El modelo desarrollado se valida en un edificio real de gran tamaño, compuesto por 91 habitaciones, en el que una persona se puede desplazar de una a otra habitación. Como consecuencia, existe un total de 8281 posibles acciones, que podría necesitar alto esfuerzo de cómputo en el proceso de calibración. Sin embargo, el modelo de Sharma et al. (2019) logra reducir el espacio de acción en un 90%, es decir, se logró un algoritmo bastante eficiente. Por otro lado, Yao et al., (2019), realizan una simulación del movimiento de personas en lugares muy confluídos, mediante algoritmos de RL, con el objetivo de realizar una evacuación eficiente frente a alguna emergencia, evitando obstáculos. Los datos se obtienen a través de videocámaras de vigilancia, en donde se evalúa el comportamiento de los peatones.

Una de las primeras investigaciones que abordaron la problemática de la evacuación peatonal frente a tsunamis, es de García Avellaneda, (2019), quien analiza la evacuación peatonal en el distrito de La Punta frente a un tsunami, como un modelo simple que representa el “problema de la ruta más corta”. En su modelo considera variables como: el tráfico vehicular, la velocidad de recorrido de los peatones, las distancias entre nodos, flujo peatonal por nodo. Interactúa con dichas variables para poder encontrar una ruta óptima (Figura 9). En su investigación resalta la influencia negativa del uso excesivo de vehículos para el proceso de evacuación frente a este desastre, ya que disminuye el tiempo de evacuación final. Logra demostrar que durante la noche se salva mayor porcentaje de la población que durante el día, debido a que en el día se presenta un mayor tráfico vehicular por la zona.

(Mas et al., (2020), realizaron una simulación del movimiento peatonal en rutas de evacuación horizontal, en donde analizan la cantidad de posibles sobrevivientes. Es decir, la cantidad de personas que logran escapar de la zona de inundación frente a un tsunami. Luego de 1000 simulaciones consiguen calibrar correctamente el modelo, eliminando movimientos desordenados de los peatones, conocidos como “bucles”, obteniendo un patrón de movimiento claro y ordenado, como se aprecia en la Figura 10.

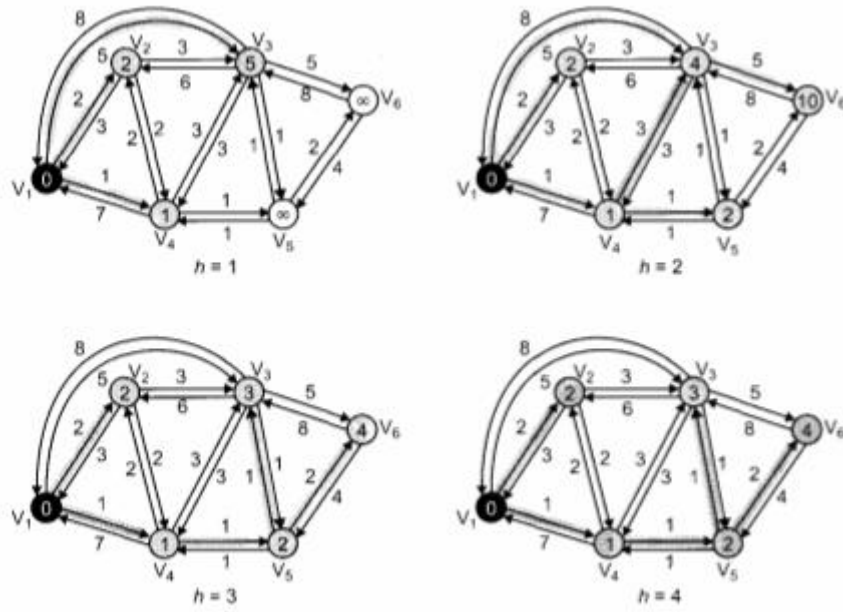


Figura 9. Problema de la ruta más corta. (García Avellaneda, 2019)






Figura 10. Simulación de movimiento peatonal frente a un tsunami (Mas et al., (2020)

En resumen, el aprendizaje por reforzamiento ha aparecido como una poderosa herramienta frente a problemas de evacuación peatonal, las cuales pueden ser aplicadas en un sistema de evacuación inteligente frente a tsunamis, con el objetivo de tener medidas de prevención de riesgos de este desastre muchos más eficientes.

CAPÍTULO III: Marco Teórico

En el presente inciso se mencionarán algunos conceptos clave para entender las componentes de un algoritmo de Reinforcement Learning, así como las hipótesis y enfoques en su desarrollo. Asimismo, se definirán los conceptos de curvas de fragilidad, que ayudarán a determinar un escenario sísmico más realista en caso de ocurrir un tsunami post-sismo.

3.1 Algoritmo fundamental del Reinforcement Learning

Aprender a través de la interacción con el entorno es una idea fundamental que subyace casi todos los principios de la inteligencia y el aprendizaje. Sutton & Barto, (2014) explican el algoritmo fundamental del aprendizaje por reforzamiento, en el que un agente interactúa con un entorno. El **agente** se encuentra en un **estado** (S_t), que le proporciona información, sobre la cual decidirá qué **acción** (A_t) tomar, para la cual recibirá una **recompensa** (R_t), ya sea positiva o negativa, por cada acción que ejecuta. Mediante una serie de simulaciones el agente recibe una secuencia de recompensas. Dichas recompensas se van acumulando, y el monto total de las recompensas en una simulación se denomina **retorno**. De este modo, *reinforcement learning* denota una serie de métodos que buscan determinar la serie de acciones que lo llevará a obtener el máximo retorno. El diagrama de la Figura 11 muestra un esquema de la interacción del agente con su **entorno** (en inglés **environment**).

3.1.1 El proceso de decisión de Markov

El modelo de *reinforcement learning* presenta como hipótesis inicial que la información que recibirá en el agente será únicamente en el presente, y esta misma determinará su comportamiento a futuro, por lo que ignoramos completamente los sucesos pasados. Dicha hipótesis se denomina *proceso de decisión de Markov*. Bajo dicha condición podemos establecer que el estado en un instante t_{i+1} depende solo del estado en un instante t_i y la acción tomada en un instante t_i .

3.1.2 La política del agente

El objetivo final del agente es encontrar la política óptima (π), es decir la regla que utilizará para maximizar el retorno. La mejora de la política se puede realizar mediante dos formas: el aprendizaje *on-policy* y *off-policy*. En el primero, el agente aprende utilizando la misma política con la que actúa desde el inicio de la simulación, por lo que la interacción con el entorno se hace con la misma política actual, como es el caso del método SARSA. Mientras que en el aprendizaje *off-policy* el agente aprende con una política diferente a la que utiliza para recolectar datos, como se realiza en los algoritmos Q-learning




Figura 11. Algoritmo fundamental del RL. (Sutton & Barto, 2014)

3.1.3 Exploración y explotación

“Un modelo de *reinforcement learning* se calibra mediante continuas simulaciones. Durante el proceso de calibración, el agente emplea dos enfoques a la hora de tomar decisiones” (Sutton & Barto, (2014):

- Exploración: el agente elige acciones que no son necesariamente las mejores según su conocimiento actual, para obtener más información sobre el entorno, y puede generar la posibilidad de obtener mayores recompensas a futuro
- Explotación: el agente selecciona las mejores acciones conocidas hasta un momento determinado, las cuales, según su experiencia, le han proporcionado la mayor recompensa posible.


El agente debe equilibrar cuidadosamente estos dos enfoques para maximizar las recompensas a largo plazo, dado que, si el agente solo explota, corre el riesgo de no descubrir acciones potencialmente mejores en el futuro. Mientras que, si el agente explora demasiado, puede perder recompensas a corto plazo por probar constantemente nuevas acciones (Sutton & Barto, 2014).

3.2 Temporal Difference Learning

Podemos decir que TDL es una simulación de Montecarlo mejorada, ya que en el método de MC tiene como objetivo una estimación del valor $G(t)$, y necesita toda una simulación para llegar a dicho objetivo, sin tomar en cuenta posibles cambios antes de la obtención de dicho valor (Sutton & Barto, 2014).

El TDL tiene dos tipos de actualización del valor: El Q- Learning, y el State - Action – Reward – State – Action (SARSA), para este caso, utilizaremos el SARSA como método de actualización.

Dado un conjunto de pares “estado – acción”, seguidos cada uno de una recompensa. SARSA consiste en actualizar el valor de luego de cada par estado – acción, posterior a recibir una recompensa:



3.3 Curvas de fragilidad

Las curvas de fragilidad representan la probabilidad de que una estructura exceda un determinado estado de daño en función de un parámetro que define la intensidad sísmica. Este parámetro puede ser la aceleración pico del suelo (PGA), o la pseudo aceleración de una familia de estructuras para un período estructural (T), que en su mayoría de veces es de T=0.30 o 1 segundo. Estas curvas se utilizan para estimar el riesgo sísmico de grupos de edificios con características estructurales similares. Las curvas de fragilidad se pueden generar mediante observaciones de campo, basándose en la opinión de expertos y utilizando métodos analíticos. (Blondet & Velásquez, 2005). En la Figura 13 se puede observar un ejemplo de curva de fragilidad. Se puede apreciar que para un valor de la aceleración pico del suelo (PGA) de 0.3g, se tiene una probabilidad de excedencia del estado de daño completo del 37%, a un daño severo del 72%, un daño moderado del 92%, y un daño leve del 100%.

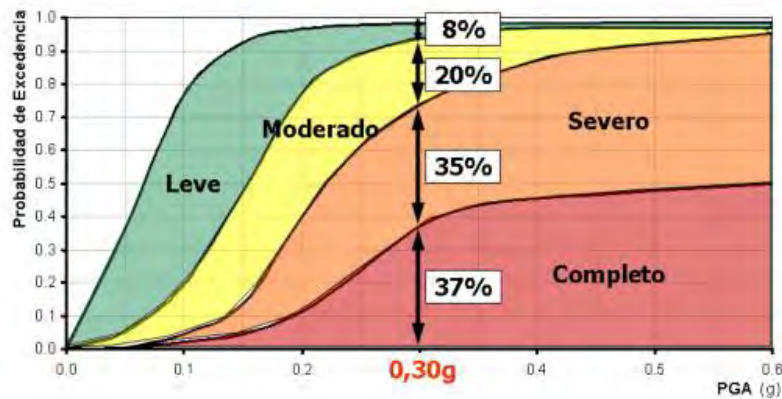


Figura 12. Ejemplo de curva de fragilidad. (Blondet & Velásquez, 2005)

CAPÍTULO IV: Aplicación del Reinforcement Learning a la evacuación peatonal

En el siguiente capítulo se indicarán las componentes del modelo de RL desarrollado para determinar las rutas de evacuación por tsunami, así como las ecuaciones que determinan su aprendizaje, y por último, las hipótesis básicas del modelo del entorno.

4.1 Modelamiento del entorno

Nuestro modelo del entorno está conformado por todas las entidades físicas que intervienen en el proceso de evacuación. El medio de transporte, pistas y veredas se representa mediante un grafo, donde las calles conforman un conjunto de “**bordes**” ξ ; por un conjunto de **nodos** N , que se forma mediante la intersección de dos bordes. En adición al medio de transporte, los peatones y los puntos de evacuación también forman parte del entorno. La Figura 14 ilustra un entorno compuesto por un grafo, un peatón y un punto de evacuación.

Definimos un “borde (e_i)”, que representa a una calle o pista, como un vector de tres componentes, donde $e_i = (n_j, n_k, w_i)$. Donde sus componentes $\{n_j, n_k\} \in N$, son los nodos extremos del borde y $w_i \in \mathbb{R}$ es el ancho de la calle. El valor de w_i se asume con un valor constante en todo el borde. Adicionalmente un nodo $n_i = (x_i, b_i)$, donde $x_i \in \mathbb{R}^2$, denota las coordenadas del nodo en mención, y $b_i = \{0,1\}$, es un parámetro binario, el cual es igual a 1 cuando se trata de un punto de evacuación y 0, en cualquier otro caso.

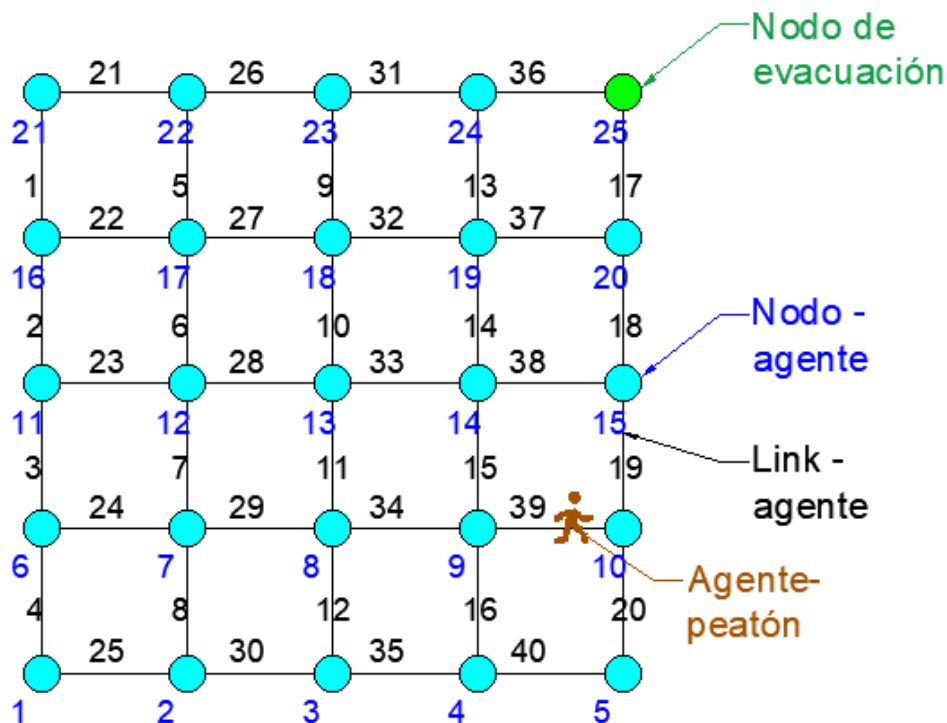


Figura 13. Modelo de un entorno conformado por nodos, links, peatón y nodo de evacuación.

Con estos componentes del entorno, podemos definir los siguientes operadores:

$$B(e_i) = (n_j, n_k) \quad (4.1)$$

$$C(n_i) = (e_j | n_i \in B(e_j)) \quad (4.2)$$

donde $B(e_i)$ representa los nodos finales del extremo del borde e_i , y $C(n_i)$ es un operador que proporciona los bordos que tienen a n_i como uno de sus nodos extremos. Por ejemplo, en el caso de la Figura 15, para el borde 34, tendríamos $B(e_{34}) = (n_8, n_9)$, y para el nodo 8, tendríamos $C(n_8) = (e_{11}, e_{12}, e_{29}, e_{34})$.

Definimos a P como el conjunto de peatones, donde p_i representa un **agente - peatón**. Cada agente – peatón está definido por cuatro parámetros: $p_i = (y_i, v_i, t_i, s_i)$, donde y_i representa el vector posición, v_i es el vector que representa la velocidad del peatón, t_i indica el tiempo inicial de evacuación, y s_i , es un parámetro binario $s_i \in (0,1)$, en el que se asigna un valor de 1 si el agente a conseguido llegar a un punto de evacuación y 0 si continúa evacuando.

Para la presente investigación modelamos la región del Callao conforme a lo indicado líneas arriba. Uno de los primeros pasos consiste en identificar que zonas del área del proyecto representan las zonas a evacuar y cuáles son las zonas seguras. Para esto se empleó, las cartas de inundación proporcionadas por la Dirección de Hidrografía y Navegación (DHN), a través de su página web <https://www.dhn.mil.pe/cnat/cartas-inundacion>, el cual incluye una estimación de las zonas a inundarse ante la ocurrencia de un tsunami generado por sismo de Mw 9.0. (Figura 15).






Figura 14. Mapa de inundación frente a un tsunami en el Callao



Figura 15. Modelo de Líneas de la zona inundable del Callao

De dicho mapa se obtuvieron las coordenadas UTM de las zonas de interés. Otra información relevante para modelar la zona inundable en el Callao es la información georreferenciada de las pistas y veredas, que serán empleadas y con ayuda de Open Street Map, a través de su página web <https://www.openstreetmap.org/>, se extrajo información geográfica para procesarla en Qgis, donde se generó un modelo de líneas de la zona, excluyendo puntos, y algunos tipos de capas, dado que solo incluimos calles, pasajes y

avenidas (Figura 16). En este caso, la zona inundable abarca todo el Distrito de La Punta y parte del Distrito de Callao.

Con respecto al conjunto de nodos (es decir, las coordenadas de los extremos de las calles), se empleó el mapa de inundación (Figura 16) para separar a los nodos ordinarios y los nodos de evacuación. Es decir, nodos cuyas coordenadas estaban fuera de la zona de inundación se clasificaba como nodo de evacuación. De manera similar, nodos con coordenadas dentro de la zona de inundación son clasificados como nodos ordinarios. Es importante notar que, en adición a los nodos fuera de la zona de inundación, existen edificios altos en el Distrito de la Punta que han sido oficialmente declarados como puntos de evacuación vertical (Figura 17 y 18).



Figura 16. Estructuras para evacuación vertical. (Mas et al., 2012).




Figura 17. Modelo de la zona inundable y puntos de evacuación de La Punta




Figura 18. Cálculo de la población del área de estudio.

Con respecto al número de agentes—peatón, se generó un número de peatones por cada nodo, según datos de la población del censo del 2017 del INEI. Se determinó el área de la zona de estudio y la densidad poblacional de cada distrito que se abarca (La Punta y Callao), con lo que finalmente se tiene un valor aproximado de la población. Debido a que no se contaba con la distribución espacial de la población en la zona, el valor de la población se distribuyó equitativamente en cada nodo generado, obteniendo nueve personas por nodo. Se obtuvo finalmente una población de 53926 habitantes dentro del área de

estudio-todo el distrito de La Punta y la zona inundada del distrito del Callao, como se observa en la Figura 19.

4.2 Algoritmo de Reinforcement Learning del modelo

El algoritmo del modelo está conformado por el sistema guía y el comportamiento del peatón. Considere un agente – peatón arbitrario moviéndose en cierto borde del modelo. Una vez que el agente - peatón llega un nodo n_p , en un determinado tiempo t_i , percibe información de las calles adyacentes a dicho nodo, es decir de los bordes en $C(n_p)$. En ese momento, decimos que el peatón se encuentra en un estado S_{np} , y es aquí donde se encuentra con el conjunto de posibles acciones a tomar $A(S_{np})$. Para continuar con el proceso de evacuación, el agente–peatón debe elegir una calle de $C(n_p)$ y continuar moviéndose. Es decir, la acción que toman los agentes-peatón son elecciones de las calles por el cual realizan su evacuación. Cuando el agente toma una acción $a(n_p)$, se moviliza a un nuevo nodo n_r y llega en un tiempo t_j . Al llegar a dicho punto, el sistema guía le brinda información sobre el nivel de densidad de las calles que se encuentran adyacentes a dicho nodo n_r , pasando de un estado S_{np} a S_{nr} . Es en este momento donde se calcula la recompensa y se verifica si el punto n_r es un punto de evacuación o no. En caso de ser un punto de evacuación se le asigna un puntaje positivo $R^{positivo}$, el cual es un valor constante positivo, se actualiza el valor del retorno asociado al agente-peatón y se da por finalizada la evacuación. En caso de no ser un punto de evacuación, se le asigna una recompensa negativa $R^{negativo}$, el cual es proporcional a la diferencia del tiempo $(t_j - t_i)$, como se indica en la Figura 20, el sistema guía actualiza el retorno, para posteriormente sugerir una acción, y el peatón en base a dicha acción se moviliza a otro punto, y así continua hasta llegar a un punto de evacuación. Dicho proceso se muestra en la Figura 21.

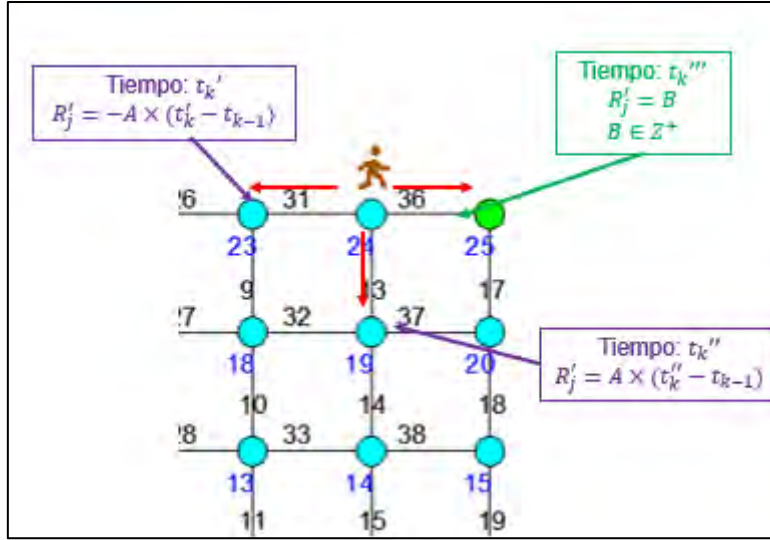


Figura 19. Asignación de puntaje por tipo de nodo.

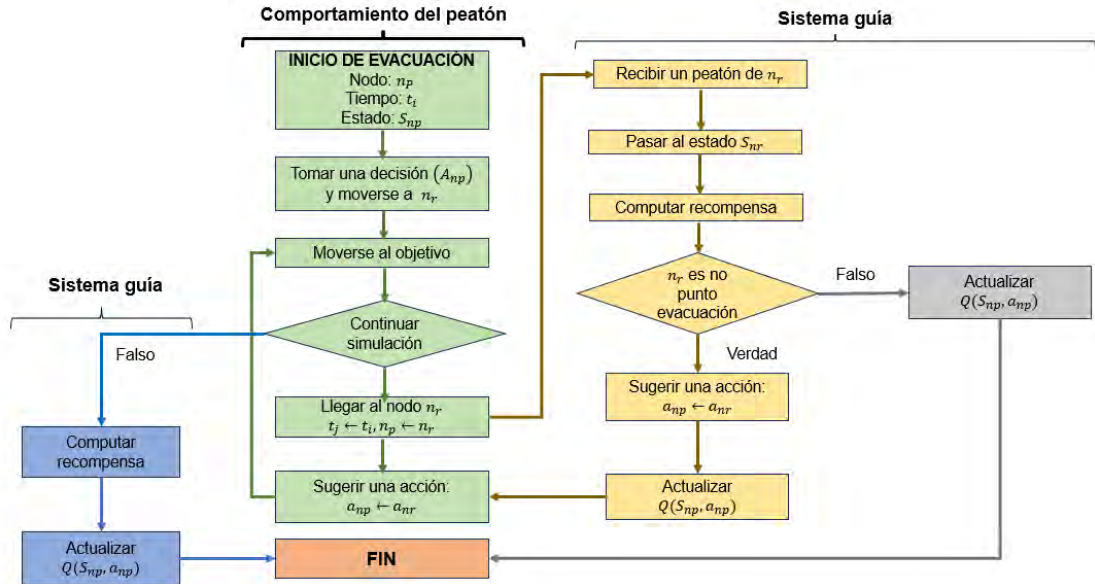


Figura 20. Diagrama de flujo del algoritmo del RL del modelo generado. (Mas et al., 2024).

Como se mencionó anteriormente, la recompensa cuantifica el resultado de cada acción individual, y la suma de todas las recompensas obtenidas para cada conjunto de acciones, en cada instante de tiempo se denomina retorno. Para la definición del retorno, se emplea la siguiente expresión:

$$G_{t_0} = R_{t_1} + \gamma R_{t_2} + \gamma^2 R_{t_3} + \dots + \gamma^{T-1} R_{t_T} \quad (4.3)$$

$$G_{t_0} = \sum_{k=0}^{T-1} \gamma^k R_{t_{k+1}} \quad (4.4)$$

donde G_{t_0} representa el valor del retorno total en el tiempo t_0 , $\gamma < 1$ es un factor de descuento y t_T representa el tiempo en el que un peatón llega a un punto de evacuación.

El valor esperado del retorno en un tiempo t_i , cuando el estado $S_{np} = s$, y se decide tomar la acción $A_{np} = a$, se define como la función acción – valor $q(s|a)$:

$$q(s, a) = E[G_{t_i} | S_{np} = s, A_{np} = a], \forall a \in A(s) \quad (4.5)$$

En *reinforcement learning*, se emplea un enfoque probabilístico para tomar las decisiones. Es decir, en lugar de usar la ecuación (4.3) o (4.4) para tomar decisiones, se emplea la ecuación (3.5). El objetivo del algoritmo es maximizar el valor esperado del retorno total obtenido $v(s)$, de esta forma se obtiene la ruta de evacuación más adecuada, acorde con la siguiente expresión:

$$a^*(s) = \max_{a \in A(s)} q(s, a) \quad (4.6)$$

donde a^* denota la mejor acción a tomar si el peatón se encuentra en un estado s . El objetivo principal del proceso de aprendizaje es calcular las funciones acción-valor de todos los posibles estados que se pueda presentar en un proceso de evacuación, las cuales son aproximadas mediante simulaciones sucesivas, donde agentes peatón intentan alcanzar un punto de evacuación. Cuando un agente peatón llega a un nodo, el sistema guía le indica un borde óptimo para llegar a un nodo de evacuación. En ese mismo instante, dicho agente peatón comunica al sistema guía la información obtenida del instante anterior, para actualizar la función de valor estimada, mediante la siguiente expresión:

$$Q(S_{np}, A_{np}) \leftarrow Q(S_{np}, A_{np}) + \alpha [R_{t_j} + \gamma Q(S_{np}, A_{np}) - Q(S_{np}, A_{np})] \quad (4.7)$$

donde $Q(S_{np}, A_{np})$ es la aproximación de la función valor para un estado S_{np} y una acción A_{np} y α el parámetro de tamaño de paso. Esta ecuación de actualización del valor se deriva del método SARSA (Sutton & Barto, 2014).

Con respecto a ciertos detalles de una simulación de evacuación, la velocidad de cada agente – peatón depende de la densidad de personas en su entorno cercano, y se determina mediante la siguiente expresión:

$$|V_i| = \begin{cases} 1.19 & \text{si } \rho_i < 0.3 \\ 1.19 - \frac{(\rho_i - 0.3)(1.19 - 0.2)}{3 - 0.3} & \text{si } 0.3 \leq \rho_i < 3 \\ 0.2 & \text{si } \rho_i \geq 3 \end{cases} \quad (4.8)$$

donde ρ_i representa la densidad alrededor del agente “i”, en la posición y_i . Dicha densidad se calcula en cada intervalo de 2 metros de cada borde e . El nivel de densidad d_{ej} , está en función a la densidad peatonal máxima de un borde e_j , y es cuantificado por tres valores:

$$|d_{ej}| = \begin{cases} 0 & \text{si } \rho^{ej} < 0.3 \\ 1 & \text{si } 0.3 \leq \rho^{ej} < 3 \\ 2 & \text{si } \rho_i \geq 3 \end{cases} \quad (4.9)$$

donde ρ^{ej} representa la máxima densidad peatonal en personas/ m^2 en el borde e_j .

Una vez definidas estas componentes, podemos representar el vector estado S, por ejemplo, del grafo de la Figura 14, para el nodo 15, tendríamos el siguiente vector $S_{n_{15}} = (n_{15}, d_{10}, d_{11}, d_{28}, d_{33})$. Cabe mencionar que el vector estado es dinámico conforme avanza el tiempo.

4.3 Hipótesis del proceso de evacuación

Se asumirán algunas hipótesis durante proceso de evacuación, como se menciona a continuación, lo cual facilita el desarrollo del algoritmo de aprendizaje:

- Debido a que no se cuenta con información precisa respecto a la distribución espacial de los peatones en el área de estudio, se plantea la hipótesis de que la población se encuentra en el área de inundación en el momento del tsunami. Esto permite asignar exactamente la misma cantidad de personas en todos los puntos del modelo del entorno, sin considerar ningún punto “vacío”
- No se ha considerado interrupción en las vías, por lo que los peatones pueden circular libremente a través de todos los bordes del modelo.
- La evacuación es completamente peatonal. No se considerará algún otro tipo de medio de transporte, como vehículos o bicicletas. Debido a esta condición se considera que la velocidad de caminata tiene un rango de 0.2 a 1.19 m/s
- El tsunami cubre la zona en un tiempo máximo de 30 minutos, este tiempo será el intervalo de análisis, para cuantificar la cantidad de peatones que logran llegar a un punto de evacuación, dado que es el tiempo en que se estima que llegan las olas de mayor altura del tsunami post-sismo, según la carta de inundación del CNAT (Figura 22).

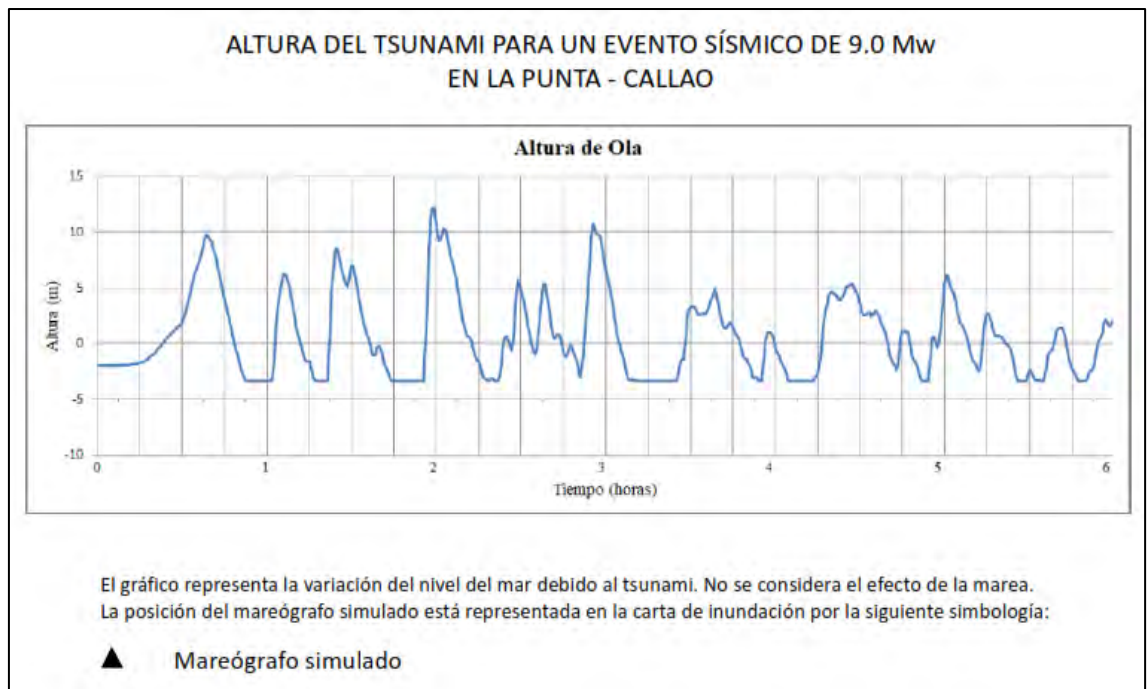


Figura 21. Altura del Tsunami para un evento sísmico de 9.0 Mw en La Punta, Callao vs el tiempo.

*Fuente: Dirección de Hidrografía y Navegación (DHN),
<https://www.dhn.mil.pe/cnat/cartas-inundacion>*


CAPÍTULO V: Simulaciones numéricas

En el siguiente capítulo se mostrarán los resultados obtenidos por las simulaciones, tanto en la zona inundable del Callao, determinada según la carta de inundación obtenida, así como en el distrito de La Punta. En este último se analizará un escenario sísmico más realista, considerando el daño en las edificaciones de evacuación vertical post-sismo. Se analizará también el número de simulaciones realizadas en el programa para tener un modelo correctamente calibrado.

5.1 Simulaciones en la zona inundable del Callao

Nuestro algoritmo logra determinar el patrón de movimiento para cada peatón mediante indicaciones en los nodos que indican la dirección del peatón en cada instante de tiempo, como se muestra en la Figura 23. Dichas indicaciones están en constante actualización y varían en función a la variación del nivel de densidad peatonal en las calles. Como se mencionó en el capítulo anterior, se han considerado tres niveles de densidad (Ecuación 3.9). En otras palabras, la simulación consiste en la evacuación de peatones que están guiados por un sistema inteligente. El sistema aprende mediante simulaciones previas (proceso de calibración) cuantificando acciones con puntajes negativos cuando no se llega a un punto de evacuación y puntajes positivos cuando el peatón logra evacuar.

Se puede observar que el patrón de movimiento tiende a dirigirse a las calles con bajo nivel de densidad, de color negro, evitando pasar por calles con alta congestión, de color rojo.






Figura 22. Patrón de movimiento peatonal en un instante de tiempo arbitrario.

En las simulaciones presentadas tenemos las líneas en negro que representan las calles del entorno, los puntos en azul que representan a los peatones, los puntos en rojo representan los puntos de evacuación. Además, se tiene un mapa de calor que indica la velocidad de movimiento peatonal, la cual varía de 0 a 1.19 m/s, como se observa en la Figura 24.

Luego de 5000 simulaciones, considerando un total de 54837 peatones uniformemente distribuidos en los nodos al inicio de las simulaciones, se puede observar que para un tiempo aproximado de 30 minutos se tiene un aproximado de 37559 evacuados, lo que indicaría un 68.86% de evacuados del total. Recordar que se emplean 54837 para obtener una magnitud consistente al censo de INEI del 2017.



Figura 23. Proceso de evacuación de peatones empleando el sistema guía durante el minuto 23.

De un total de 54837 peatones, 37559 han alcanzado una zona segura

Luego de realizadas 5000 simulaciones, se observa cómo se incrementan el número de evacuados, conforme se realizan más simulaciones. Cabe resaltar que inicialmente existen persona ya evacuadas, dado que se encuentran fuera de la zona inundable desde el inicio del proceso de evacuación. Por ello, para evaluar el rendimiento del modelo, se cuantifica el incremento de evacuados, determinado mediante la diferencia del número de evacuados en el tiempo igual a 30 minutos, y el número de evacuados inicial. Se evaluó el rendimiento del modelo, se pudo observar que, a partir de las 1000 simulaciones, no hay un incremento considerable en el número de evacuados (Figura 25). En las primeras simulaciones del proceso de evacuación, pudieron observarse algunos movimientos peatonales sin ningún patrón fijo, regresando a la misma posición inicial durante todo el tiempo de simulación. Este fenómeno se conoce como “bucles”. El incremento de número de simulaciones permite eliminar “bucles”, en el proceso de evacuación, generando un movimiento más ordenado siguiendo una ruta constante.





Figura 24. Gráfico del incremento de número de evacuados vs número de simulaciones, en un tiempo de 30 minutos.

Otro punto importante a destacar es la congestión que se genera en algunos puntos, ya que la barra en la derecha indica la velocidad de movimiento del peatón en m/s (Figura 26). La alta incidencia del color rojo de los peatones indica una reducción de velocidad, por lo tanto, se infiere que hay congestión en dichas zonas, impidiendo un tránsito fluido. De los resultados de las simulaciones, se observa gran congestión peatonal a partir de los 10 minutos de iniciado el proceso de evacuación, hasta finalizado el tiempo de 30 minutos, como se observa en la Figura 26.

Asimismo, una vez terminado el tiempo de 30 minutos, un gran porcentaje de la población se quedaría a mitad de camino, debido a la lejanía de la zona no inundable y debido a las dificultades que presentaría al realizar un proceso de evacuación.



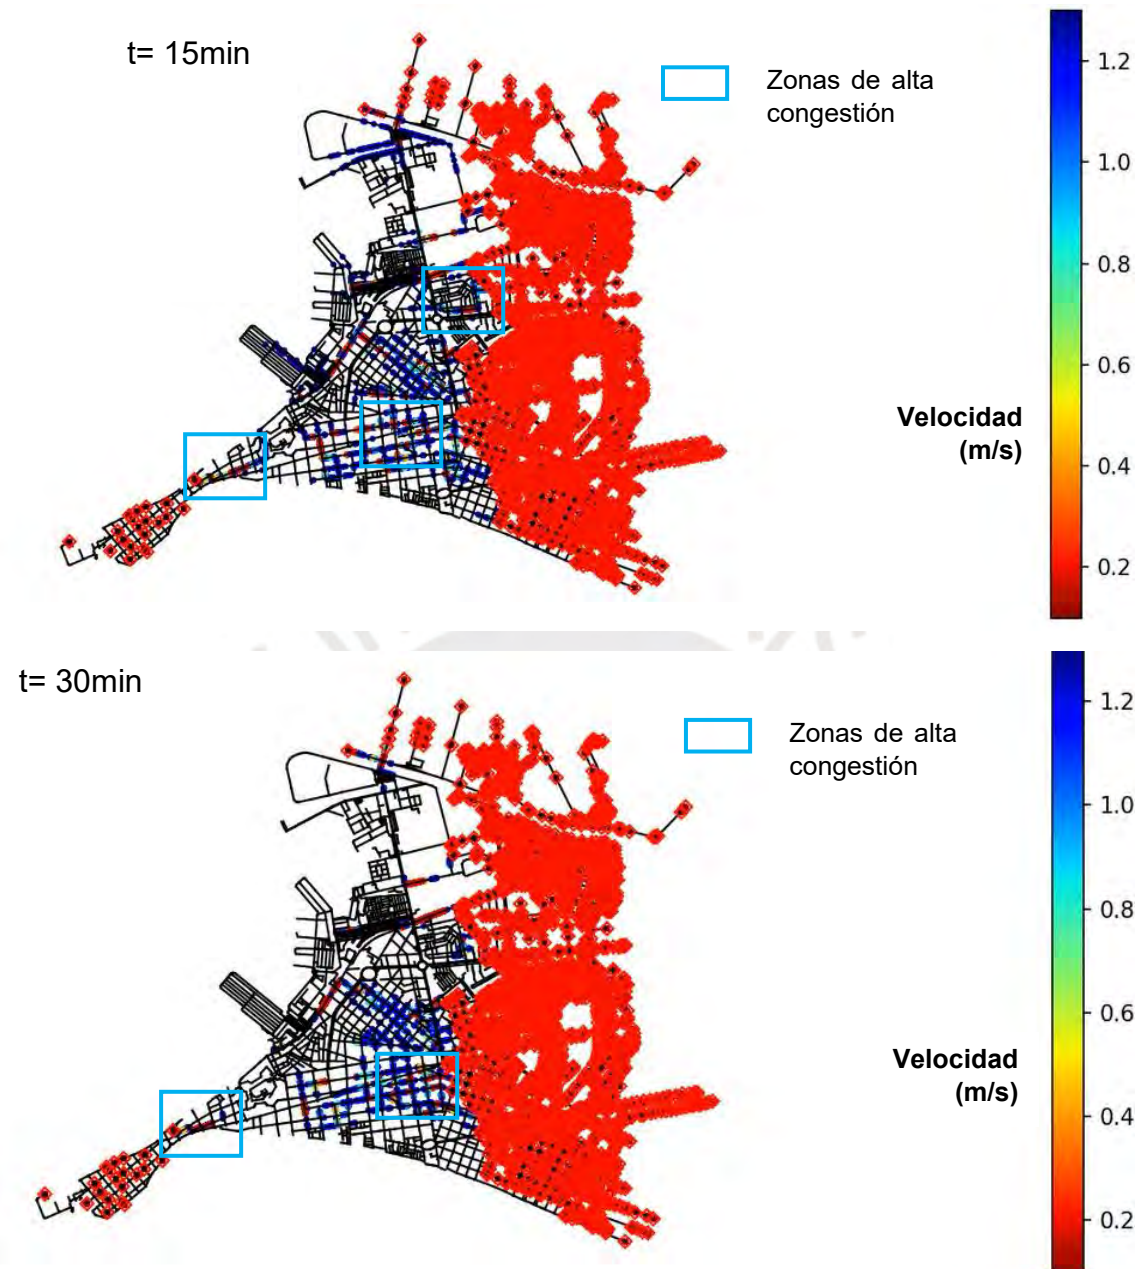


Figura 25. Congestión peatonal en distintos instantes de tiempo.

Las marcas con forma de rombo denotan la ubicación de nodos de evacuación. Es decir, ubicación de nudos fuera de la zona de inundación y la ubicación de estructuras para evacuación vertical. Las marcas circulares denotan la ubicación de los peatones y su color está en función a su velocidad de movimiento, el cual varía de 0.2 m/s (rojo) a 1.19 m/s (azul).

En distintos instantes de tiempo se puede notar congestión en muchas zonas, en especial en el límite del distrito de la Punta con el Callao, y en las intersecciones de la Avenida Miguel Grau con el Jiron Arica, Jiron Vigil y Jiron Francisco Pizarro (Figura 27a), y la Avenida Guardia Chalaca con la Avenida República de Panamá (Figura 27b); estas zonas corresponden a los tramos finales de evacuación horizontal.




Figura 26. Zonas de mayor congestión peatonal frente a una evacuación por tsunami.

De las simulaciones anteriores, se distingue claramente las zonas con tendencia a evacuación vertical y horizontal, si verificamos el proceso de evacuación en el minuto 30 de la Figura 27. Se observa que la mayor parte de peatones del distrito del Callao se dirige hacia el este. Es decir, fuera de la zona de inundación. Por otro lado, peatones del distrito de La Punta y una pequeña porción del distrito del Callao optan por dirigirse a las estructuras de evacuación vertical.

5.2 Escenario sísmico frente a un tsunami en el distrito de La Punta

Como se mencionó anteriormente, el distrito de la Punta es el distrito con mayor índice de riesgo frente a un tsunami. Asimismo, se observa que el patrón de movimiento peatonal tiende a dirigirse a puntos de evacuación vertical ubicados en La Punta, desde una determinada área del distrito del Callao. Por ello, se realizarán simulaciones considerando la zona en la cual la población tiende a realizar evacuación vertical, acorde con las simulaciones realizadas en el capítulo anterior, obteniendo el modelo del entorno indicado en la Figura 28.

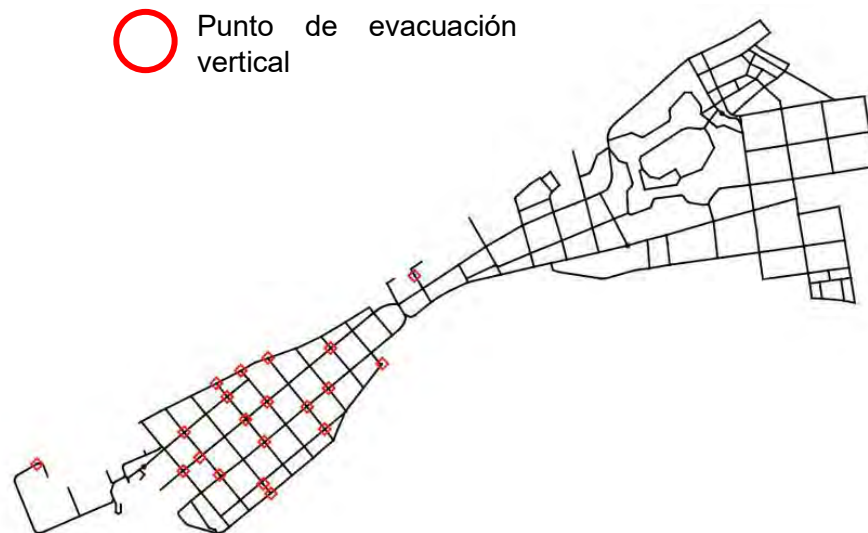


Figura 27. Modelo del entorno del distrito de la Punta.




Figura 28. Gráfico comparativo de la población evacuada en cada simulación y en la ruta más corta.

Se necesitaron un aproximado de 10000 simulaciones para calibrar correctamente el modelo y tener un movimiento peatonal “coherente” sin bucles, como se observa en las primeras simulaciones, y se optimizó el proceso de evacuación, hallando de la ruta más corta. En la Figura 29 se muestra la comparación de la población evacuada en cada simulación, con la ruta más corta. En dicha Figura se muestra cómo se incrementa la cantidad de personas evacuados y finalmente con la obtención de la ruta más corta. Para el tiempo final de 30 minutos la ruta más corta logró incrementar el número de evacuados de 4870 a 5340, casi 500 personas más. La gráfica indica que para tiempos menores a 15 minutos la ruta más corta no logra incrementar el número de supervivientes, esto debido al nivel de congestión que se genera en los primeros minutos en las calles que brindan en el camino más corto, mientras que en los instantes finales de tiempo las vías se encuentran más libres por lo que se logra obtener mayor cantidad de evacuados en la ruta más corta.

En la Figura 30, se observa el patrón de movimiento peatonal para distintos instantes de tiempo.





Figura 29. Simulaciones numéricas distrito de la Punta.

Se observa congestión en la zona del cuello de botella, donde se reducen las velocidades de caminata de los peatones, justamente donde se encuentra un

punto de evacuación vertical. De estas simulaciones, se puede notar que en un tiempo de 30 minutos no se conseguiría evacuar completamente. Se obtienen finalmente 5330 evacuados de un total de 8406, lo que corresponde a un porcentaje del 63 % de la población.

Si analizamos el estado post – sismo de las estructuras de evacuación vertical, debemos considerar un estado de daño en el que no sea posible ni seguro para la vida de las personas utilizar dichos edificios, y para ello consideramos el estado de daño severo previo al colapso, ya que las olas del tsunami podrían generar el posterior colapso de una estructura previamente dañada severamente por el sismo. Es por ello, que, para analizar un escenario más realista, se propone utilizar las curvas de fragilidad, que permiten determinar la probabilidad de excedencia de un estado de daño de una edificación, para distintas condiciones, en este caso, para la pseudo aceleración para un período de 1 segundo, lo cual se determina mediante mapas de riesgo sísmico (Figura 31).

Para el distrito de La Punta tenemos una pseudo aceleración de aproximadamente 800 cm/s^2 , lo que equivale aproximadamente a $0.8g$. Con dicho valor, determinamos la probabilidad de excedencia de estados de daño extensivo, muy cercano al colapso, considerando que la población objetivo no consideraría evacuar en un edificio muy dañado, ya que podría poner en peligro su seguridad. La topología estructural a analizar será de pórticos de concreto armado de 3 a 5 niveles (Figura 32).






Figura 30. Mapa de Pseudoaceleraciones para un período de $T=1$ seg. en la zona de La Punta. (Pulido et al., 2015).

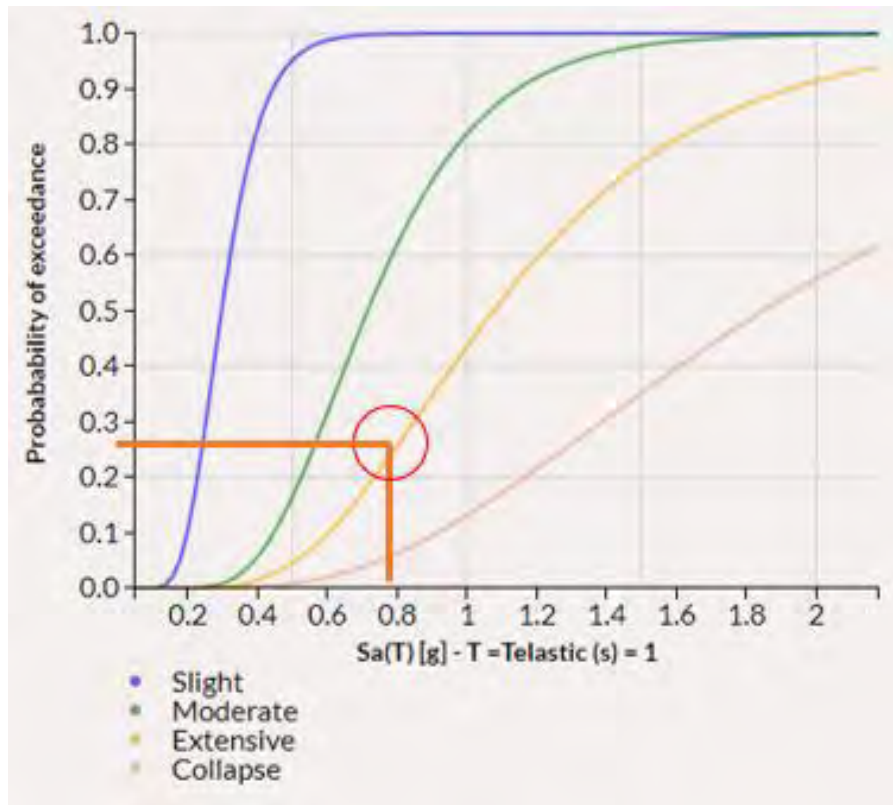


Figura 31. Determinación de la probabilidad de excedencia de un estado de daño de los edificios de evacuación vertical. (Villar-Vega et al., 2017).

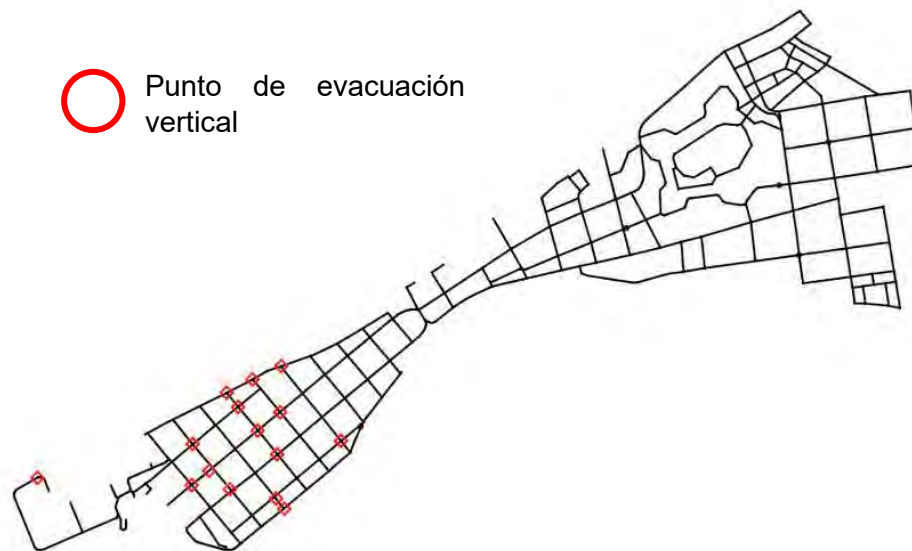
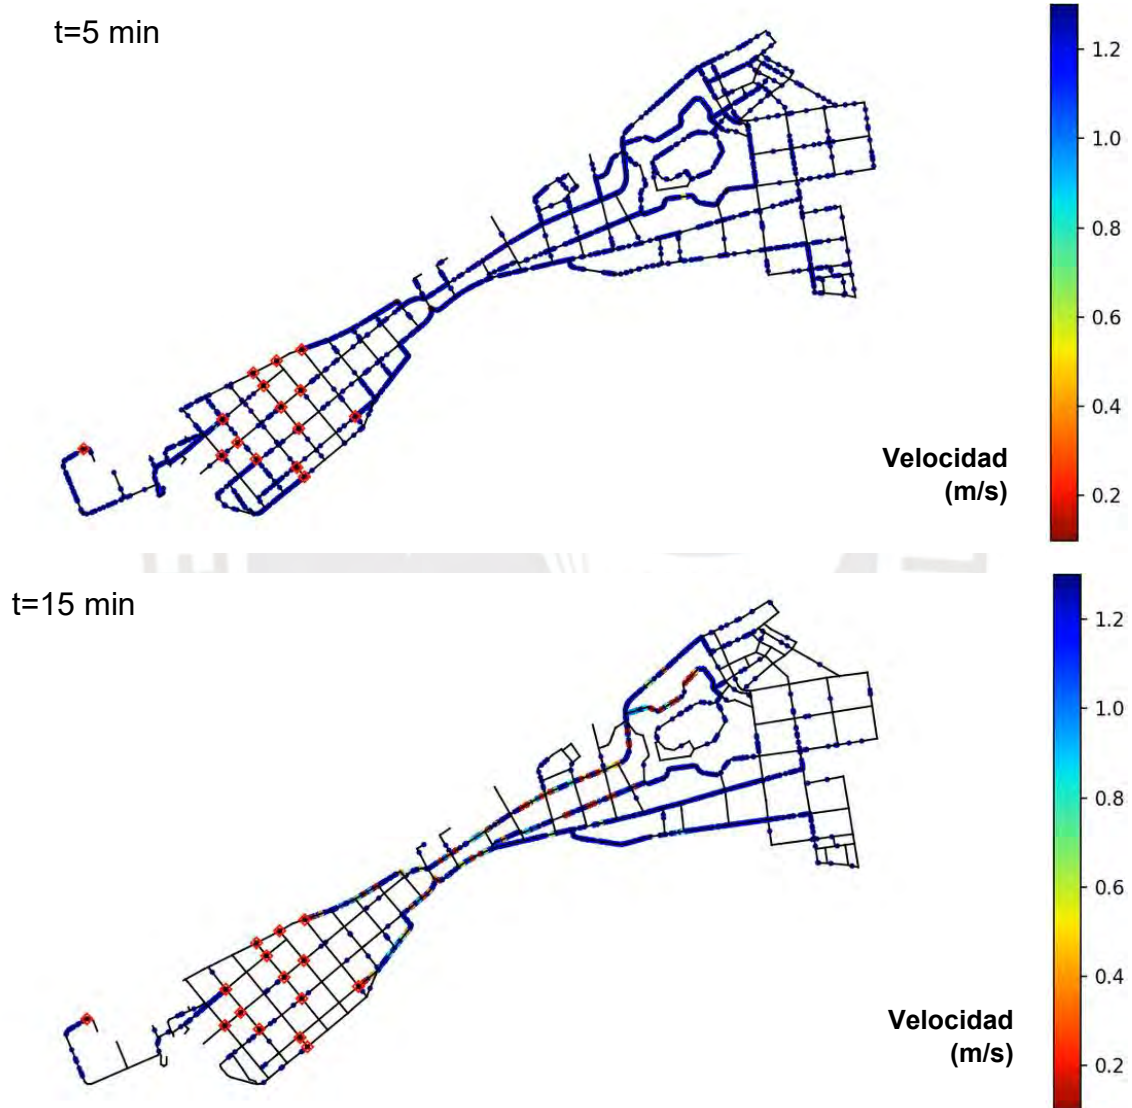


Figura 32. Modelo del entorno de la Punta, considerando daño de estructuras de evacuación vertical.

Se tiene una probabilidad de excedencia del estado de daño extensivo del 25%, por lo que, de las 20 edificaciones de evacuación vertical existentes, se eliminarán 5 de ellas, considerando el peor escenario, en donde no se podrá

evacuar en las edificaciones cercanas al límite de La Punta con el Callao, como se muestra en la Figura 33.

Para realizar la calibración del modelo, se necesitaron 10000 simulaciones para el caso sin daño de edificaciones de evacuación vertical y 15000 simulaciones considerando el daño, debido a la aparición de “bucles” y movimiento no uniforme de los peatones. Ello indica que cuanto más se tarde el modelo en lograr un puntaje positivo se requerirán un mayor número de simulaciones.



t=30 min




Figura 33. Simulaciones numéricas distrito de la Punta, considerando daño de edificios de evacuación vertical.

El patrón indica un movimiento peatonal de la zona limítrofe del Callao y la Punta hacia el punto de evacuación vertical más cercano. Se observa un mayor porcentaje de peatones que se quedan en el camino una vez finalizado el tiempo de 30 minutos, obteniendo 4155 evacuados, lo que corresponde al 49% de la población, es decir menos de la mitad.

En la Figura 35, se muestra el gráfico comparativo de la población evacuada en cada simulación versus la ruta más corta, logrando incrementar el número de evacuados.

En la Figura 36, se realiza un gráfico comparativo de la cantidad de personas evacuadas en el tiempo, para ambos casos. Finalmente, como se observa en la Figura 36, notamos que a partir de los 10 minutos de iniciada la evacuación, se reduce considerablemente la cantidad de personas que logran evacuar, teniendo una reducción de 1755 personas sin lograr evacuar.




Figura 34. Número de personas evacuadas por cada simulación vs la ruta óptima. Caso con daño de edificios de evacuación vertical.




Figura 35. Número de evacuados versus tiempo en el distrito de la Punta.



CONCLUSIONES

De la investigación realizada se tienen las siguientes conclusiones:

- Según las simulaciones realizadas en el modelo trabajado, y bajo las hipótesis mencionadas, existe una clara tendencia en el patrón de movimiento peatonal frente a un eventual tsunami en el distrito del Callao, en el que un porcentaje de la población tiende dirigirse a las estructuras de evacuación vertical de la Punta para lograr salvaguardar su vida. Por otro lado, un porcentaje de la población presenta una tendencia a la evacuación horizontal, alejándose de la zona inundable. Este segundo grupo no lograría cumplir su objetivo, si solo realiza evacuación peatonal, debido a la lejanía de la zona no inundable. Por ello, existe una necesidad de edificaciones de evacuación vertical en la zona, que incrementen el número de supervivientes frente a un eventual tsunami
- El modelo de RL representa la ruta más óptima para que un peatón pueda llegar a una zona de evacuación. En un escenario realista puede que la simulación realizada no se cumpla completamente. Por otro lado, si consideramos también que la población a evacuar no tomaría la ruta más corta si a simple vista se muestra congestionada, tampoco se representaría un escenario completamente realista. Adicionalmente, se espera que, en un futuro a mediano plazo, la tecnología de telecomunicaciones y los celulares inteligentes jugarán un rol importante guiando a las personas en un proceso de evacuación. Desde dicha perspectiva, las simulaciones empleando RL se acercan más a dicho escenario del futuro.
- Con respecto al proceso de calibración del modelo de RL, en una situación donde los habitantes puedan contar con un sistema guía, el desempeño del proceso de evacuación puede mejorar, como se observa en las simulaciones, el modelo de RL logró mejorar el desempeño del peatón. Cuando no se consideraron daños en los edificios de evacuación vertical, se necesitan alrededor de 10000 simulaciones para calibrar correctamente el modelo, y para obtener rutas óptimas de evacuación (eliminar bucles en las trayectorias de los peatones). Por otro lado, en el caso en el que se consideran daños y colapso post sismo de los edificios de evacuación vertical, donde se redujeron los puntos de evacuación vertical de recompensa positiva, se necesitaron 15000 simulaciones para calibrar correctamente el modelo. Ello indica la necesidad de incrementar el número de simulaciones cuando se tiene menores puntos de recompensa positiva en el modelo (es decir, menores puntos de evacuación). Al eliminar los edificios de evacuación vertical se requiere más tiempo de simulación, para que todos los peatones puedan alcanzar un punto de evacuación, generando mayor esfuerzo computacional.
- Frente a un escenario sísmico más realista, donde luego de ocurrido un sismo de gran magnitud se prevé, que un 25% de los edificios de evacuación vertical, no estarán en funcionamiento, bajo dicho escenario,

el modelo determinó que solo lograría evacuar el 50% de la población del distrito de la Punta. Es por ello, que se requieren mayores estudios que ayuden a determinar ubicaciones óptimas o factibles, de evacuaciones verticales, considerando una zona densamente poblada como es el distrito de La Punta.



RECOMENDACIONES

- Para líneas futuras de investigación, se sugiere realizar un modelo que incluya la interrupción de vías, frente a un posible colapso de algunas edificaciones ante un sismo de gran magnitud. Asimismo, se recomienda incluir la capacidad máxima de aforo en los edificios de evacuación vertical.
- Se recomienda considerar puntos estratégicos para la ubicación de posibles edificaciones de evacuación vertical dentro del distrito del Callao, y verificar como se incrementa la cantidad de evacuados en el tiempo.



BIBLIOGRAFÍA

- Abarca, F., & Lizana, F. (2020). Educación sobre riesgo de desastres. Métodos didácticos en la enseñanza sobre tsunamis en Chile. *Revista de Geografía Espacios*, 9(18), 55–69. <https://doi.org/10.25074/07197209.18.1555>
- Blondet, M., & Velásquez, J. (2005). Estimación de pérdidas sísmicas mediante curvas de fragilidad. *ResearchGate*, January 2005, 11.
- Carranza, L. (2021). *EDIFICACIONES PARA EVACUACION VERTICAL ANTE TSUNAMIS*.
- CENEPRED. (2017). Escenario de riesgo por sismo y tsunami para Lima y Callao. *Centro Nacional de Estimación, Prevención, Reducción Del Riesgo de Desastres*. https://sigrid.cenepred.gob.pe/sigridv3/storage/biblioteca/10354_escenario-de-riesgo-por-sismo-y-tsunami-para-lima-y-callao.pdf
- CISMID, & UNI. (2010). *Evaluación de la amenaza frente a tsunami para Lima y Callao*. 1–46.
- Esteban, M., Tsimopoulou, V., Mikami, T., Yun, N. Y., Suppasri, A., & Shibayama, T. (2013). Recent tsunamis events and preparedness: Development of tsunami awareness in Indonesia, Chile and Japan. *International Journal of Disaster Risk Reduction*, 5, 84–97. <https://doi.org/10.1016/j.ijdrr.2013.07.002>
- García Avellaneda, A. J. A. (2019). *Diseño de un plan de evacuación en caso de emergencia por tsunami en el distrito de La Punta usando métodos de optimización*. 1–89.
- Guilherme, Klein, & Viviane, Todt. (2023). *Inteligencia Artificial aplicada a la predicción de los niveles de alerta de actividad volcánica del Arequipa, Perú volcán Sabancaya*. 129–133.
- IFRC. (2009). *A cinco años del tsunami: Informe de situación 2004 - 2009*. https://www.ifrc.org/PageFiles/113868/Tsunami_5Yrs_Report_ES.pdf
- INDECI. (2017). Escenario sísmico para Lima Metropolitana y Callao: Sismo 8.8Mw. *Indice-Dipre*, 54. <https://www.indeci.gob.pe/objetos/secciones/Mg==/MzQ0/lista/OTk3/201711231521471.pdf>
- JICA. (2011). *Project Study on the Effective Countermeasures Project Study on the effective countermeasures against Earthquake and Tsunami Disasters*.
- Kuglitsch, M., Albayrak, A., Aquino, R., Craddock, A., Edward-Gill, J., Kanwar, R., Koul, A., Ma, J., Marti, A., Menon, M., Pelivan, I., Toreti, A., Venguswamy, R., Ward, T., Xoplaki, E., Rea, A., & Luterbacher, J. (2022). La inteligencia artificial aplicada a la reducción de riesgos de desastre: oportunidades, retos y perspectivas. *Organización Meteorológica Mundial*, 71(1), 30–37. <http://hdl.handle.net/20.500.11765/14124>
- León, J., Mokrani, C., Catalán, P., Cienfuegos, R., & Femenías, C. (2019). The role of built environment's physical urban form in supporting rapid tsunami evacuations: Using computer-based models and real-world data as

- examination tools. *Frontiers in Built Environment*, 4(January). <https://doi.org/10.3389/fbuil.2018.00089>
- León, J., Zamora, N., Castro, S., Jünemann, R., Gubler, A., & Cienfuegos, R. (2019). Evacuación vertical como medida de mitigación del riesgo de tsunamis en Chile. *Cigiden*, July.
- Maly, E., & Suppasri, A. (2020). The Sendai Framework for Disaster Risk Reduction at Five: Lessons from the 2011 Great East Japan Earthquake and Tsunami. *International Journal of Disaster Risk Science*, 11(2), 167–178. <https://doi.org/10.1007/s13753-020-00268-9>
- Mas, E., Adriano, B., & Koshimura, S. (2012). *An Integrated Simulation of Tsunami Hazard and Human Evacuation in La Punta, Peru*. 8(2), 11. http://ares.tu.chiba-u.jp/peru/pdf/output/2013/2013JDR_Mas.pdf
- Mas, E., Moya, L., Gonzales, E., & Koshimura, S. (2024). *Reinforcement Learning-Based Tsunami Evacuation Guidance System*.
- Mas, E., Moya, L., & Koshimura, S. (2020). Tsunami evacuation guidance using Reinforcement Learning Algorithm. *17 World Conference on Earthquake Engineering*, 1, 2020.
- Park, H., Liu, D., & Namilae, S. (2022). *Multi-Agent Reinforcement Learning-Based Pedestrian Dynamics Models for Emergency Evacuation Final Report*. June.
- Petrone, C., Rossetto, T., Baiguera, M., la Barra Bustamante, C. De, & Ioannou, I. (2020). Fragility functions for a reinforced concrete structure subjected to earthquake and tsunami in sequence. *Engineering Structures*, 205(December 2019), 110120. <https://doi.org/10.1016/j.engstruct.2019.110120>
- Petrone, C., Rossetto, T., & Goda, K. (2017). Fragility assessment of a RC structure under tsunami actions via nonlinear static and dynamic analyses. *Engineering Structures*, 136(January), 36–53. <https://doi.org/10.1016/j.engstruct.2017.01.013>
- Pulido, N., Aguilar, Z., Tavera, H., Chlieh, M., Calderón, D., Sekiguchi, T., Nakai, S., & Yamazaki, F. (2015). Scenario source models and strong ground motion for future megaequakes: Application to Lima, central Peru. *Bulletin of the Seismological Society of America*, 105(1), 368–386. <https://doi.org/10.1785/0120140098>
- Sharma, J., Andersen, P. A., Granmo, O. C., & Goodwin, M. (2019). Deep Q-Learning with Q-Matrix Transfer Learning for Novel Fire Evacuation Environment. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 51(12), 7363–7381. <https://doi.org/10.1109/TSMC.2020.2967936>
- Sutton, R., & Barto, A. (2014). An introduction to reinforcement learning. *Decision Theory Models for Applications in Artificial Intelligence: Concepts and Solutions*, 63–80. <https://doi.org/10.4018/978-1-60960-165-2.ch004>
- Villar-Vega, M., Silva, V., Crowley, H., Yepes, C., Tarque, N., Acevedo, A. B., Hube, M. A., D., G. C., & Santa María, H. (2017). Development of a Fragility Model for the Residential Building Stock in South America. *Earthquake*

Spectra.

- Wang, H., Mostafizi, A., Cramer, L. A., Cox, D., & Park, H. (2016). An agent-based model of a multimodal near-field tsunami evacuation: Decision-making and life safety. *Transportation Research Part C: Emerging Technologies*, 64, 86–100. <https://doi.org/10.1016/j.trc.2015.11.010>
- Yang, Y., Yu, J., Karnati, K., Liu, D., Namilae, S., & Park, H. (2022). *Multi-Agent Reinforcement Learning- Based Evacuation Models under Emergency*. January.
- Yao, Z., Zhang, G., Lu, D., & Liu, H. (2019). Data-driven crowd evacuation: A reinforcement learning method. *Neurocomputing*, 366, 314–327. <https://doi.org/10.1016/j.neucom.2019.08.021>
- Zhang, L., Pan, Y., Wu, X., & Skibniewski, M. J. (2021). *Artificial Intelligence in Construction Engineering and Management* (Vol. 163). <http://www.springer.com/series/15087> <https://link.springer.com/10.1007/978-981-16-2842-9>

