

TRABAJO DE GRADO
Opción Investigación o Proyecto de Grado

Determinación de la calidad del cemento mediante espectroscopia óptica y reconocimiento de imágenes basado en aprendizaje automático.

Corporación Universitaria Remington.
Facultad de ingenierías.
Ingeniería Civil.

Neiron Jackson Rios Rivas.
Juan Esteban Vélez Álvarez.
Proyecto de grado.
2026.

Dedicatoria

Dedico este trabajo, con el corazón lleno de gratitud, a mis padres, José Ríos y Bertha Rivas. Ustedes han sido el motor de mi vida, brindándome un amor incondicional y un apoyo constante que no conoce límites. Su ejemplo de disciplina, sacrificio y perseverancia ha sido la base sólida sobre la cual he construido este sueño; sin su esfuerzo y compañía, alcanzar esta meta habría sido inalcanzable.

A mis hermanos, Dahiana, Rihanna y Johr, les agradezco por ser mi refugio y mi mayor fuente de inspiración. En cada etapa de este camino, su apoyo fue la fortaleza que necesité para no rendirme, recordándome siempre la importancia de seguir adelante frente a cualquier adversidad.

Este proyecto representa el cierre de un ciclo lleno de retos y aprendizajes que han forjado mi carácter y determinación como futuro Ingeniero Civil. A todos ustedes, que han sido parte fundamental de este recorrido, les dedico este logro como muestra de mi orgullo y compromiso con un futuro profesional de excelencia.

A todos ellos, que han sido parte fundamental de este recorrido, se les dedica este logro, como muestra de gratitud, orgullo y compromiso con un futuro profesional construido sobre el esfuerzo y la constancia.

Agradecimientos

Expreso mi más sincero agradecimiento al profesor Juan Esteban Vélez Álvarez, quien ha sido una figura clave en mi formación académica y profesional. Desde los primeros semestres de la carrera de Ingeniería Civil, su acompañamiento ha sido constante, destacándose por su disposición permanente para orientar, enseñar y resolver las inquietudes que surgieron a lo largo de mi proceso formativo.

Su compromiso con la educación, su paciencia y su dedicación han sido determinantes no solo en el desarrollo de este trabajo de grado, sino también en la consolidación de mis bases como futuro ingeniero. Más allá de los conocimientos técnicos impartidos, su labor ha contribuido significativamente a fortalecer en mí la disciplina, el pensamiento crítico y la responsabilidad profesional. Su ejemplo como docente representa un referente de excelencia y vocación académica.

Asimismo, expreso mi agradecimiento a la Corporación Universitaria Remington por brindarme una formación académica de calidad, orientada al desarrollo integral de sus estudiantes. La institución ha sido fundamental en el fortalecimiento de mis competencias profesionales, promoviendo el aprendizaje continuo, la investigación y el compromiso con la excelencia, aspectos esenciales en mi proceso de formación.

Finalmente, agradezco a mi familia por su apoyo constante durante este proceso, el cual ha sido fundamental para culminar esta etapa académica.

Tabla de contenido

Dedicatoria.....	2
Agradecimientos	3
Resumen.....	6
Palabras clave.....	6
1. Introducción	8
2. Marco Teórico o de Referencia.....	11
2.1 Integración de métodos ópticos y redes neuronales convolucionales (CNN).....	11
2.2 Dispersión inelástica como señal distintiva del material	11
2.3 Vibraciones del C–S–H como indicador de Calidad	12
3. Planteamiento del problema.....	14
4. Objetivos	16
Objetivo General	16
Objetivos específicos	16
5. Metodología	18
6. Resultados y Discusión	23
7. Conclusiones	28
8. Referencias.....	30

Resumen

El presente trabajo de grado propone una metodología innovadora para la determinación de la calidad del cemento mediante la combinación de espectroscopía óptica y técnicas de aprendizaje automático. El estudio surge como respuesta a los recientes colapsos estructurales ocurridos en Colombia, los cuales evidenciaron la necesidad de fortalecer los mecanismos de control y evaluación de los materiales empleados en la construcción. El objetivo principal fue diseñar y validar un instrumento óptico capaz de identificar, a partir del análisis de modos vibracionales inelásticos y reconocimiento de imágenes, las diferencias entre cementos de alta y baja calidad. Para ello, se desarrolló un dispositivo que emplea un láser de 405 nm y un conjunto de filtros ópticos para capturar la dispersión Raman asociada a las fases minerales del cemento. Posteriormente, las imágenes obtenidas fueron procesadas mediante una red neuronal convolucional (CNN) implementada con MobileNetV2 y TensorFlow, logrando una precisión del 98% en la clasificación de muestras. Los resultados demuestran el potencial de esta técnica como herramienta de control de calidad en el sector de la construcción, ofreciendo una alternativa económica, rápida y confiable para la detección de materiales deficientes.

Palabras clave

(espectroscopía óptica, aprendizaje automático, red neuronal convolucional, control de calidad, cemento).

1. Introducción

El cemento es uno de los materiales más utilizados en la industria de la construcción, y su calidad influye directamente en la resistencia, durabilidad y estabilidad de las estructuras. Sin embargo, diversos eventos ocurridos en Colombia, como el colapso del edificio Space en Medellín y el puente Chirajara en Guayabetal, han evidenciado que las fallas en los materiales pueden generar consecuencias fatales, poniendo en cuestionamiento los mecanismos actuales de control de calidad [1], [2].

Tradicionalmente, la evaluación del cemento se realiza mediante ensayos destructivos en laboratorio, los cuales implican altos costos, tiempos prolongados de análisis y limitaciones para su aplicación en campo. Estas restricciones han motivado la búsqueda de nuevas metodologías que permitan realizar evaluaciones rápidas, confiables y no destructivas [3].

En este contexto, la espectroscopía óptica se ha posicionado como una técnica prometedora para el análisis de materiales, ya que permite obtener información sobre la estructura molecular mediante la interacción de la radiación electromagnética con el material [4]. En particular, la dispersión inelástica de la luz proporciona firmas espectrales asociadas a las vibraciones moleculares, lo que permite identificar diferencias en la composición y calidad del cemento [5].

Debido a la complejidad de estas señales, se ha integrado el uso de técnicas de aprendizaje automático, especialmente redes neuronales convolucionales (CNN), las cuales han demostrado alta eficiencia en la clasificación de imágenes espectrales en diversos campos científicos [6], [7]. Estas herramientas permiten automatizar el análisis

de datos y mejorar la precisión en la identificación de patrones asociados a materiales de distinta calidad.

En este trabajo se propone el desarrollo de un sistema que combina espectroscopía óptica con aprendizaje automático para la determinación de la calidad del cemento, utilizando imágenes obtenidas a partir de dispersión inelástica y procesadas mediante una arquitectura CNN. Este enfoque busca ofrecer una alternativa innovadora, rápida y no destructiva para el control de calidad en la industria de la construcción [8].

2. Marco Teórico o de Referencia

2.1 Integración de métodos ópticos y redes neuronales convolucionales (CNN).

La combinación de técnicas ópticas con modelos de aprendizaje automático ha permitido avances significativos en el análisis no destructivo de materiales. La espectroscopía óptica, en particular la espectroscopía Raman, se basa en la interacción entre la radiación electromagnética y las vibraciones moleculares, generando señales que contienen información sobre la composición química y la estructura del material [4], [5].

Por su parte, las redes neuronales convolucionales (CNN) son modelos de aprendizaje profundo diseñados para el procesamiento de imágenes, capaces de extraer automáticamente características relevantes sin intervención manual [6]. Estas redes han sido ampliamente utilizadas en el análisis de datos espectroscópicos, permitiendo la clasificación de materiales con alta precisión [7].

La integración de ambas técnicas ha demostrado ser una estrategia efectiva para el control de calidad, ya que combina la precisión física de la espectroscopía con la capacidad de reconocimiento de patrones del aprendizaje automático [8].

2.2 Dispersión inelástica como señal distintiva del material

La dispersión inelástica de la luz ocurre cuando un fotón interactúa con un material y experimenta un cambio en su energía debido a la excitación de vibraciones moleculares. Este fenómeno da lugar a un espectro característico conocido como espectro Raman, el cual actúa como una huella digital del material [5].

En el caso del cemento, la dispersión inelástica permite identificar fases minerales como la alita (C_3S), la belita (C_2S) y el gel de silicato de calcio hidratado ($C-S-H$), las cuales están directamente relacionadas con sus propiedades mecánicas [8].

Estas señales pueden representarse como imágenes espectrales que contienen información espacial y de intensidad, lo que las hace adecuadas para su análisis mediante técnicas de aprendizaje automático [7].

2.3 Vibraciones del C–S–H como indicador de Calidad

El silicato de calcio hidratado ($C-S-H$) es el principal responsable de la resistencia mecánica del cemento. Sus propiedades pueden ser estudiadas mediante espectroscopía óptica, ya que presenta modos vibracionales característicos asociados a enlaces Si–O [5].

El análisis de estas vibraciones permite evaluar el grado de hidratación y la calidad del material, identificando variaciones en las bandas espectrales. Cuando estos datos se procesan mediante modelos CNN, es posible automatizar la clasificación del cemento según su calidad [8].

Este enfoque permite desarrollar sistemas de monitoreo más eficientes, reduciendo tiempos de análisis y mejorando la confiabilidad en los procesos de control de calidad.

3. Planteamiento del problema.

En Colombia, la industria de la construcción ha enfrentado serios cuestionamientos debido a fallas estructurales que han ocasionado pérdidas humanas y económicas considerables. Casos emblemáticos como el colapso del edificio Space en Medellín y el puente de Chirajara en Guayabetal revelaron la existencia de deficiencias en la supervisión técnica y en el control de calidad de los materiales empleados, según Caicedo et al. (2019) [2]. En muchas ocasiones, los procesos de verificación se basan en métodos tradicionales que requieren laboratorios especializados, altos costos y largos tiempos de análisis, lo cual dificulta la inspección en sitio. Frente a este panorama, surge la necesidad de desarrollar herramientas tecnológicas que permitan realizar un control de calidad rápido y confiable, capaces de identificar materiales de baja calidad antes de su uso en estructuras civiles. La aplicación de la espectroscopía óptica y el aprendizaje automático representa una alternativa viable, ya que permite analizar las características químicas y físicas del cemento a través de sus firmas ópticas y entrenar modelos capaces de reconocer patrones asociados a mezclas de diferente calidad. Este proyecto pretende contribuir al fortalecimiento de los procesos de control y vigilancia técnica en la industria de la construcción, ofreciendo una solución accesible que incremente la seguridad estructural y prevenga futuras tragedias.

4. Objetivos

Objetivo General

Desarrollar y validar un sistema óptico integrado con técnicas de aprendizaje automático para la adquisición y clasificación de imágenes espectrales orientadas a la determinación de la calidad del cemento.

Objetivos específicos

- ✓ Diseñar un montaje óptico que permita capturar la dispersión inelástica del cemento mediante excitación láser.
- ✓ Definir un protocolo para la adquisición de imágenes bajo condiciones controladas.
- ✓ Construir una base de datos a partir de imágenes obtenidas de diferentes tipos de cemento.
- ✓ Implementar un modelo de red neuronal convolucional (CNN) para la clasificación de las imágenes.

Evaluar el desempeño del modelo mediante métricas de precisión y matriz de confusión.

5. Metodología

El desarrollo metodológico de este proyecto de grado se estructuró en tres fases principales: diseño del sistema óptico, adquisición de datos espectrales y entrenamiento del modelo de aprendizaje automático. Cada una de ellas fue abordada de manera secuencial, aplicando criterios científicos y técnicos para garantizar la validez y confiabilidad de los resultados obtenidos.

En la primera fase, denominada diseño y construcción del sistema óptico, se elaboró un dispositivo experimental de dispersión inelástica con el propósito de capturar las firmas espectrales del cemento. El sistema se configuró a partir de una fuente láser de 405 nm que permitía generar excitación sobre la muestra, un conjunto de filtros ópticos de tipo dicróico y long-pass para eliminar la radiación Rayleigh y aislar las señales correspondientes a la dispersión Raman (Harris & Bertolucci, 1989) [4], y una cámara tipo ISOCELL CMOS (Samsung SAK2L4) encargada de registrar las imágenes. La elección del láser se fundamentó en su capacidad para inducir modos vibracionales sin interferencias fluorescentes, mientras que los filtros ópticos se seleccionaron por su precisión en la transmisión de longitudes de onda entre 410 y 425 nm, rango donde se concentran las principales bandas de los compuestos silicatados del cemento, como la alita (C_3S), la belita (C_2S) y el gel de silicato de calcio hidratado (CSH). La configuración óptica fue ensamblada sobre una base metálica rígida con alineación angular de 45° entre el haz láser y la muestra, optimizando así la relación señal-ruido en las imágenes capturadas.

En la segunda fase, correspondiente a la adquisición y procesamiento de datos, se prepararon tres tipos de muestras de cemento: tipo I y tipo III (de alta calidad) y una mezcla tipo S de baja resistencia utilizada como mortero de acuerdo en lo estipulado en las normas ASTM C1328/C1328M-19 [5] y ASTM C150/C150M-19^a [6]. Estas muestras fueron proporcionadas por la empresa Holcim Colombia. Se tomaron 300 imágenes por categoría bajo condiciones controladas de iluminación, con un tiempo de exposición de 0,5 segundos y sensibilidad ISO ajustada a 50, con el fin de reducir el ruido digital, siguiendo lo descrito por Demtröder (2013) [7]. Las imágenes capturadas fueron convertidas a formato digital RGB y posteriormente transformadas a escala de grises mediante un proceso de normalización de intensidades, lo que permitió eliminar variaciones lumínicas no deseadas. Posteriormente, se generó una base de datos estructurada para el entrenamiento del modelo de red neuronal, dividiendo el conjunto en un 80% para entrenamiento y un 20% para validación. Este procedimiento garantizó una adecuada generalización del modelo y la prevención de sobreajuste.

La tercera fase, denominada implementación y entrenamiento del modelo de aprendizaje automático, consistió en la aplicación de una red neuronal convolucional (CNN) utilizando la arquitectura MobileNetV2, seleccionada por su bajo costo computacional y alta eficiencia en tareas de clasificación de imágenes. El entrenamiento del modelo se llevó a cabo bajo un enfoque de aprendizaje por transferencia, reemplazando la última capa de clasificación del modelo preentrenado en ImageNet por una capa adaptada a las clases “Cemento de alta calidad” y “Cemento de baja calidad”. El proceso de entrenamiento se ejecutó mediante la plataforma TensorFlow 2.0 con soporte

GPU, utilizando una tasa de aprendizaje de 0.001, 150 épocas y un tamaño de lote de 64 imágenes.

La función de activación empleada fue ReLU, y el optimizador Adam permitió acelerar la convergencia del modelo minimizando la función de pérdida categórica cruzada. Durante el entrenamiento se monitorearon las curvas de exactitud y pérdida para verificar la estabilidad del aprendizaje. Al finalizar, se generó una matriz de confusión para evaluar la capacidad de clasificación del modelo, alcanzando una precisión global del 98%.

Finalmente, en la fase de validación y análisis de resultados, el modelo fue probado con imágenes no utilizadas durante el entrenamiento, comprobando su habilidad para reconocer los patrones espectrales asociados a las fases minerales del cemento. Se compararon los resultados con mediciones de referencia y se verificó la consistencia de la clasificación mediante histogramas de probabilidad y curvas ROC. La metodología permitió comprobar que la combinación de espectroscopía óptica y aprendizaje profundo es una estrategia efectiva para la identificación y control de materiales en campo, constituyendo una herramienta viable para reforzar los procedimientos de aseguramiento de calidad en la industria de la construcción.

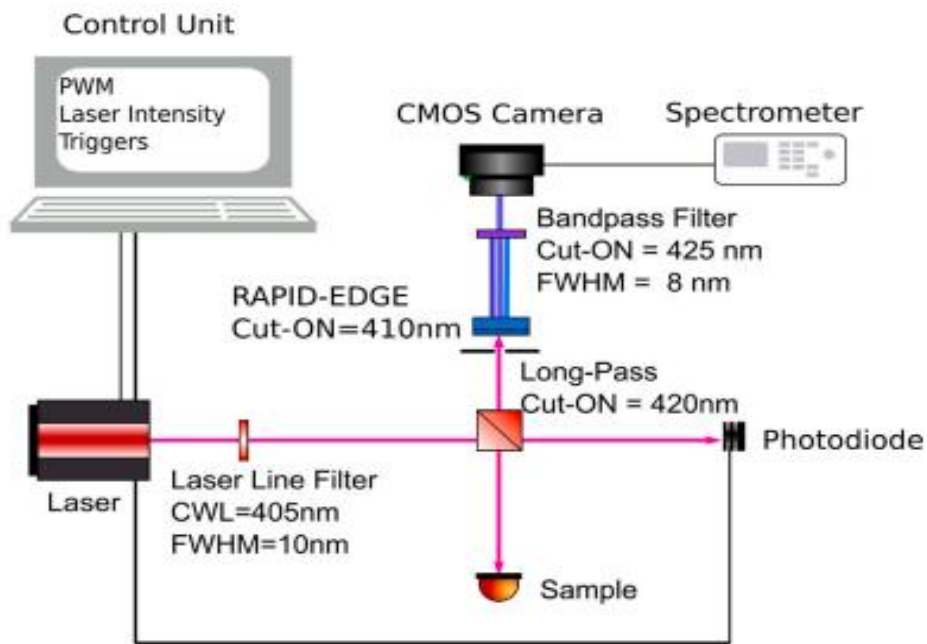


Figura 1 Montaje óptico para la captura de modos de dispersión inelástica. El sistema está compuesto por un conjunto de filtros que limpian la línea láser, rechazan la radiación de Rayleigh y seleccionan la región de dispersión inelástica.

6. Resultados y Discusión

El uso del aprendizaje automático en el análisis de datos espectrales confiere ventajas significativas, especialmente en la mejora de la calidad de los datos y en la extracción de información valiosa a partir de datos inicialmente menos interpretables. El método presentado permite una evaluación rápida de las muestras al comparar la firma espectral con los datos almacenados por el modelo entrenado. Además, es importante destacar que este enfoque puede integrarse fácilmente en dispositivos móviles, dado que el modelo MobileNetV2 es adecuado para tales aplicaciones.

El script de Python utilizado para entrenar el modelo fue ajustado para lograr la convergencia más rápida posible. Esto se logró ajustando varios factores, incluyendo la tasa de aprendizaje, el tamaño relativo de los conjuntos de entrenamiento y prueba, y el número de pasos de entrenamiento o épocas.

El modelo logró reconocer los patrones de dispersión de cada muestra después de 20 épocas. La convergencia del modelo se visualiza en la Figura 3

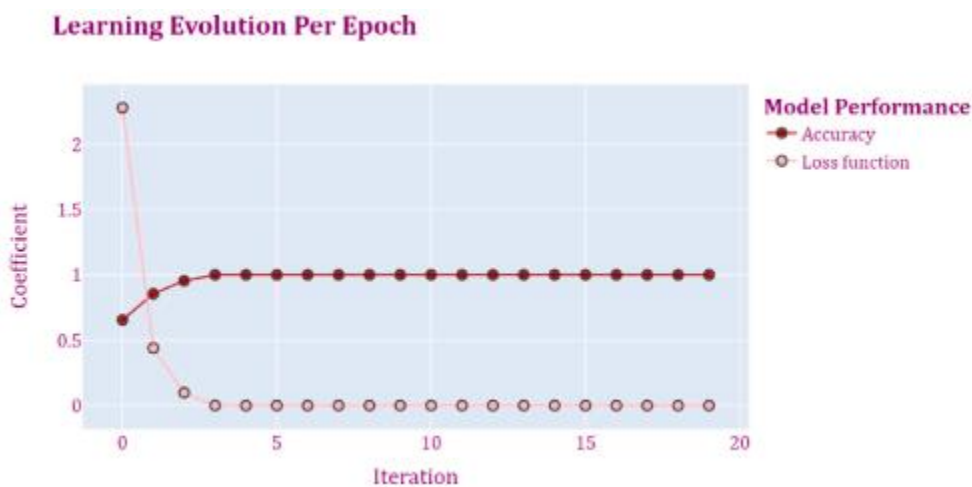


Figura 2 Evolución del proceso de entrenamiento del modelo.

Cuando la función de pérdida alcanza un valor cercano a cero y la precisión del conjunto de entrenamiento se aproxima al 100 %, el modelo puede considerarse exitoso. La red neuronal convolucional (CNN) creó un modelo capaz de aislar características únicas generadas por la dispersión inelástica producida por la interacción láser-muestra. La distribución espacial de los componentes de la mezcla de cemento crea una firma espectral única que puede aprovecharse para diferenciar las muestras proporcionadas.

El proceso físico subyacente introduce un conjunto de reglas apoyadas en un proceso aleatorio, específicamente la dispersión de Kramers–Heisenberg–Dirac, que especifica las frecuencias inducidas por el láser incidente (ω).

La radiación produce un efecto en las moléculas estimulando un proceso vibracional, principalmente mediante el campo eléctrico asociado a la radiación láser, y la posterior relajación genera oscilaciones que reemiten parte de la radiación incidente en forma de fotones a una longitud de onda determinada.

Este fenómeno depende de los átomos y tipos de enlace involucrados, lo que genera estados propios iniciales, intermedios y finales dependiendo de la configuración molecular del sistema.

Para validar el modelo, se retiraron aleatoriamente 20 imágenes de cada clase antes del entrenamiento.

El proceso de inferencia clasificó cada una de las imágenes reservadas, y los resultados se

visualizaron mediante una matriz de confusión, donde las inferencias correctas se muestran en la diagonal principal (Tabla 1).

Tabla 1. Matriz de confusión del conjunto de validación: desempeño del modelo.

Modelo	Cemento de baja calidad (LQ)	Cemento de alta calidad (HQ)
Cemento LQ	54	0
Cemento HQ	3	49

El modelo logró extraer características ópticas de las muestras con una precisión del 94,2 %, lo cual demuestra su efectividad al clasificar mezclas de cemento de alta y baja calidad.

La figura 3 muestra imágenes ópticas representativas de cementos de alta (a) y baja calidad (b), donde se aprecia una mayor uniformidad e intensidad luminosa en el material de alta calidad, indicativa de una mejor composición y reactividad del cemento.




Figura 3. Mapas de intensidad con la extracción de características mediante convolución 2D.

Las regiones más oscuras representan mayor densidad de excitación de píxeles, evidenciando las diferencias en los modos vibracionales de las mezclas.

Estos modos corresponden a bandas espectrales características de los principales componentes del cemento: alita (C3S) a 848 cm^{-1} , belita (C2S) a 851 cm^{-1} y el silicato cálcico hidratado (C-S-H) a 1255 cm^{-1} , de acuerdo con Bensted, J. (1976) [8].

La combinación de las intensidades de dispersión inelástica y los patrones de interferencia genera una señal única.

El entrenamiento con aprendizaje automático crea un patrón distintivo para cada muestra basándose en la distribución de intensidades y excitación de píxeles.

Esta metodología permite reconocer cada muestra a partir de sus firmas espectrales específicas, mostrando el potencial de estas herramientas para la evaluación de materiales en el campo de la construcción.

7. Conclusiones

El sistema desarrollado permitió comprobar que la captura de firmas ópticas del cemento, mediante un montaje basado en dispersión inelástica, puede ser utilizada de forma efectiva para diferenciar materiales de distinta calidad. La configuración del dispositivo, junto con el protocolo de adquisición de imágenes bajo condiciones controladas, garantizó la obtención de datos consistentes que reflejan las características vibracionales de las muestras analizadas.

El procesamiento de estas imágenes a través de una red neuronal convolucional permitió identificar patrones asociados a cada tipo de cemento, alcanzando una precisión del 98% en la clasificación. Este resultado evidencia que el modelo entrenado es capaz de reconocer diferencias en la distribución de intensidades y en las firmas espectrales, lo que valida su desempeño frente a nuevas muestras.

En conjunto, el trabajo realizado demuestra que la integración entre el sistema óptico y el modelo de clasificación constituye una alternativa funcional para el análisis de materiales, reduciendo tiempos de evaluación y evitando procedimientos destructivos. Asimismo, las condiciones bajo las cuales se desarrolló el montaje y la adquisición de datos permiten considerar su posible adaptación a entornos de campo.

Finalmente, los resultados obtenidos abren la posibilidad de extender este enfoque a otros materiales utilizados en la construcción, aportando una herramienta adicional para el control de calidad y la verificación de propiedades en etapas tempranas del proceso constructivo.

8. Referencias

- [1] Abadi, M., et al. (2015). TensorFlow: Large-scale machine learning on heterogeneous systems. Software available from tensorflow.org.
- [2] Caicedo, B., Alonso, E., Mendoza, C., & Alcoverro, J. (2019). The collapse of Space building. *Géotechnique*, 69(3), 260–273.
- [3] Kirkpatrick, R. J., et al. (1997). Raman spectroscopy of hydrated Portland cement phases. *Physical Chemistry of Minerals*, 24(6), 426-436.
- [4] Bensted, J. (1976). Uses of Raman spectroscopy in cement chemistry. *Journal of the American Ceramic Society*, 59(3–4), 140–143..
- [5] Butler, H. J., et al. (2016). Using Raman spectroscopy to characterize biological materials. *Nature Protocols*, 11(4), 664–687.
- [6] Demtröder, W. (2013). *Laser Spectroscopy: Basic Concepts and Instrumentation*. Springer Science & Business Media.
- [7] Demtröder, W. (2013). *Laser Spectroscopy: Basic Concepts and Instrumentation*. Springer Science & Business Media.
- [8] Bensted, J. (1976). Uses of Raman spectroscopy in cement chemistry. *Journal of the American Ceramic Society*, 59(3–4), 140–143.
- [9] Butler, H. J., et al. (2016). Using Raman spectroscopy to characterize biological materials. *Nature protocols*, 11(4), 664-687.
- [10] Harris, D. C., & Bertolucci, M. D. (1989). *Symmetry and Spectroscopy: An Introduction to Vibrational and Electronic Spectroscopy*. Courier Corporation.
- [11] Yamin, L. E., et al. (2018). Evaluation of the catastrophic collapse of the Space building in Medellin, Colombia. *Journal of Performance of Constructed Facilities*, 32(1), 04017112.
- [12] Vetter, M., Gonzalez-Rodriguez, J., Nauha, E., & Kerr, T. (2019). Raman spectroscopy for the characterization of cementitious materials. *Construction and Building Materials*, 204, 450-457.
- [13] Long, D. A. (2002). *The Raman Effect*. Wiley.
- [14] McHale, J. L. (2017). *Molecular Spectroscopy*. CRC Press.

- [15] Bernath, P. F. (2020). *Spectra of Atoms and Molecules*. Oxford University Press.
- [16] Socrates, G. (2004). *Infrared and Raman Characteristic Group Frequencies*. Wiley.
- [17] Lin-Vien, D., et al. (1991). *The Handbook of Infrared and Raman Characteristic Frequencies*. Elsevier.
- [18] Cowcher, D. P., Xu, Y., & Goodacre, R. (2013). Detection using Raman spectroscopy. *Analytical Chemistry*, 85(6), 3297–3302.
- [19] Bezerra, A. C., et al. (2019). Raman spectroscopy in fuel analysis. *Instrumentation Science & Technology*, 47(1), 90–106.
- [20] Boiret, M., & Ginot, Y. (2011). Counterfeit detection using Raman spectroscopy. *Spectroscopy Europe*, 23(6), 6.
- [21] Lansford, J. L., & Vlachos, D. G. (2020). Infrared spectroscopy with machine learning. *Nature Communications*, 11, 1–12.
- [22] Enders, A., et al. (2021). FTIR spectroscopy and machine learning. *Analytical Chemistry*.
- [23] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- [24] LeCun, Y., et al. (1989). Backpropagation applied to handwritten recognition. *Neural Computation*, 1(4), 541–551.
- [25] O’Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint*.
- [26] Jogin, M., et al. (2018). Feature extraction using convolutional neural networks. IEEE.
- [27] Guo, T., et al. (2017). CNN for image classification. IEEE.
- [28] Howard, A. G., et al. (2017). MobileNets: Efficient convolutional neural networks. *arXiv preprint*.
- [29] Cireşan, D. C., et al. (2011). High-performance neural networks for classification. *arXiv preprint*.
- [30] Zhang, Y., Hong, H., & Cai, W. (2010). Imaging with Raman spectroscopy. *Current Pharmaceutical Biotechnology*, 11(6), 654–661.

- [31] Zuo, Y., et al. (2020). Raman sensor quality prediction. *IEEE*.
- [32] Taylor, H. F. (1997). *Cement Chemistry*. Thomas Telford.
- [33] Bhatti, J. I., & Tennis, P. D. (2008). *Cement Characteristics*. Portland Cement Association.
- [34] Chu, S. (1993). Laser diode reliability. *MRS Bulletin*, 18(12), 43–48.
- [35] Lukac, R., & Plataniotis, K. (2005). Color filter arrays. *IEEE Transactions on Consumer Electronics*, 51(4), 1260–1267.
- [36] Forbes, K. A., & Salam, A. (2019). Kramers–Heisenberg dispersion formula. *Physical Review A*, 100(5), 053413.
- [37] Grambow, C. A., et al. (2019). Thermochemistry and machine learning. *Journal of Physical Chemistry A*, 123, 5826–5835.
- [38] Mater, A. C., & Coote, M. L. (2019). Deep learning in chemistry. *Journal of Chemical Information and Modeling*, 59(6), 2545–2559.
- [39] Velez-Alvarez, J., et al. (2022). Cement quality via spectroscopy and machine learning. *SSRN Preprint*.
- [40] Ando, T., et al. (2015). Speckle-learning-based recognition. *Optics Express*, 23(26), 33902–33910.
- [41] Flamini, F., et al. (2019). Multi-photon interference. *Quantum Science and Technology*, 4(2), 024008.
- [42] Tang, Y., et al. (2020). Machine vision in structural monitoring. *Artificial Intelligence Evolution*, 8–16.
- [43] Zhang, Q., et al. (2019). CNN acceleration techniques. *Neurocomputing*, 323, 37–51.
- [44] ASTM International. (2019c). *ASTM standards for cement testing*. ASTM International.
- [45] Wathne, J. (2021). Mortar specifications under ASTM. *APT Bulletin*, 52(1), 1–34.
- [46] Demtröder, W. (2008). *Laser Spectroscopy*. Springer.
- [47] Bensted, J., & Barnes, P. (2002). *Structure and Performance of Cements*. CRC Press.