

KLASIFIKASI SUARA JANTUNG MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* 1 DIMENSI (CNN 1D) DENGAN *PITCH SHIFTING* DAN TRANSFORMASI FFT PADA DATASET TERBATAS

Edinar Valiant Hawali, Reza Bagus Acintyasakti, Dwi Definta Oktavia Siswoyo

Abstrak: Pendeteksian dini terhadap kelainan jantung sangat penting untuk mencegah risiko komplikasi yang lebih serius. Penelitian ini bertujuan untuk mengklasifikasikan suara jantung normal dan murmur menggunakan metode *Convolutional Neural Network* (CNN) satu dimensi. Data yang digunakan merupakan sinyal phonocardiogram (PCG) yang telah melalui tahapan *preprocessing* berupa *band pass filter* Butterworth orde 4 (30 – 150 Hz), augmentasi *pitch shifting* (+2 *semitone*), dan transformasi *Fast Fourier Transform* (FFT) untuk ekstraksi fitur dalam domain frekuensi. Model CNN dilatih menggunakan skema validasi silang 5 *fold* untuk memastikan performa yang stabil di berbagai subset data. Analisis bentuk gelombang, spektrum frekuensi, dan spektrogram menunjukkan adanya perbedaan signifikan antara suara jantung normal dan murmur, serta dampak dari proses augmentasi terhadap distribusi frekuensi. Hasil evaluasi menunjukkan bahwa model mampu mencapai rata-rata akurasi sebesar 0,7615, dengan nilai *precision* sebesar 0,8533, *recall* sebesar 0,6912, dan *F1 score* sebesar 0,7517. Penelitian ini menunjukkan bahwa kombinasi *preprocessing* sinyal, augmentasi data, dan CNN satu dimensi dapat digunakan secara efektif untuk klasifikasi suara jantung. Hasil ini berpotensi untuk dikembangkan lebih lanjut dalam sistem deteksi dini gangguan jantung berbasis PCG.

Kata kunci: Suara jantung, CNN, FFT, band-pass filter, klasifikasi, validasi K-Fold.

Penyakit kardiovaskular merupakan kelompok gangguan pada jantung dan pembuluh darah yang mencakup kondisi seperti penyakit jantung koroner, penyakit serebrovaskular, dan hipertensi (Y. Wang & Denton, 2024). Penyakit kardiovaskular menjadi penyebab utama kematian global dengan angka kejadian yang terus meningkat (Kim et al., 2023). Penyakit ini disebabkan oleh gaya hidup tidak sehat seperti pola makan tinggi lemak, kurang aktivitas fisik, merokok, dan konsumsi alkohol (Jafari et al., 2023). Di negara berkembang, beban Penyakit kardiovaskular semakin besar seiring dengan urbanisasi (Huffman et al., 2011). Deteksi dini dan penanganan yang tepat sangat penting untuk menekan angka morbiditas dan mortalitas yang ditimbulkan.

Deteksi dini penyakit kardiovaskular menghadapi berbagai hambatan yang bersifat sistemik maupun individual. Secara sistemik, keterbatasan akses terhadap fasilitas kesehatan, kurangnya tenaga medis terlatih, dan infrastruktur diagnostik yang belum merata menjadi kendala utama, terutama di daerah terpencil (Benson et al., 2013). Di sisi individu, rendahnya kesadaran masyarakat terhadap faktor risiko penyakit kardiovaskular seperti ketidakpatuhan terhadap pemeriksaan kesehatan berkala (Weisman et al., 2015), serta adanya gejala awal yang sering kali tidak diketahui secara spesifik turut menghambat proses identifikasi dini. Selain itu, biaya pemeriksaan yang relatif tinggi dan kurangnya edukasi tentang pentingnya deteksi dini menyebabkan banyak kasus baru ditemukan pada tingkat lanjut, sehingga penanganan menjadi lebih kompleks dan mahal.

Deteksi dini penyakit kardiovaskular melalui analisis suara detak jantung merupakan pendekatan yang menjanjikan dalam bidang diagnostik kardiologi (Alrabie & Barnawi, 2023). Suara jantung dihasilkan oleh aktivitas katup dan aliran turbulen darah di dalam

Edinar Valiant Hawali, Reza Bagus Acintyasakti, dan Dwi Definta Oktavia Siswoyo adalah dosen Teknik Elektro Universitas Wisnuwardhana Malang.

Email: edinarvhawali@wisnuwardhana.ac.id, rezabagus@wisnuwardhana.ac.id, defintasiswoyo@wisnuwardhana.ac.id


jantung (T. E. Chen et al., 2017). Suara ini dapat mengandung informasi penting mengenai kondisi fisiologis maupun patologis sistem kardiovaskular (Qu et al., 2021). Dengan menggunakan teknik digital seperti perekaman *phonocardiogram* (PCG) dan pengolahan sinyal akustik, abnormalitas seperti murmur jantung, stenosis, atau insufisiensi katup dapat diidentifikasi secara dini (Talal et al., 2023). Integrasi metode ini dengan kecerdasan buatan, khususnya melalui algoritma pembelajaran mesin dan *Convolutional Neural Network* (CNN), memungkinkan klasifikasi otomatis antara suara jantung normal dan abnormal. Pendekatan ini tidak hanya meningkatkan efisiensi skrining, tetapi juga berpotensi memperluas akses deteksi dini di wilayah dengan keterbatasan fasilitas medis.

Oleh karena itu, perlu dilakukan penelitian untuk mengetahui bagaimana membangun dan mengimplementasikan model CNN yang efektif untuk melakukan klasifikasi suara jantung secara otomatis. Proses ini mencakup tahapan penting seperti perekaman sinyal, penerapan *band pass filter* untuk menghilangkan *noise* di luar frekuensi jantung yang relevan, normalisasi amplitudo, serta transformasi menggunakan metode *Fast Fourier Transform* (FFT). Tahapan-tahapan ini bertujuan untuk mengekstraksi karakteristik akustik yang merepresentasikan pola detak jantung. Sehingga memungkinkan CNN mengenali perbedaan antara kondisi jantung normal dan abnormal secara otomatis dan akurat.

Penelitian ini bertujuan untuk membangun model CNN yang mampu melakukan klasifikasi suara jantung secara otomatis ke dalam kategori normal dan murmur. Pengembangan model ini mencakup perancangan arsitektur CNN yang sesuai, pengolahan sinyal suara jantung untuk ekstraksi fitur yang representatif, serta evaluasi performa model menggunakan metode validasi silang K-Fold. Evaluasi ini bertujuan untuk mengukur konsistensi dan kemampuan generalisasi model pada berbagai subset data, sehingga hasil yang diperoleh dapat mencerminkan performa model secara lebih menyeluruh dan tidak bias terhadap pembagian data tertentu. Melalui pendekatan validasi silang, penelitian ini diharapkan dapat mengidentifikasi kekuatan dan kelemahan model dalam konteks klasifikasi suara jantung, serta memberikan dasar yang kuat untuk perbaikan dan pengembangan model lebih lanjut. Dengan pendekatan ini diharapkan penelitian dapat menghasilkan sistem klasifikasi yang akurat dan bisa diterapkan dalam upaya deteksi dini penyakit kardiovaskular.

METODE

Dalam penelitian ini, suara jantung diklasifikasikan menjadi 2 kelas: normal dan murmur. Metode yang digunakan pada penelitian ini seperti ditunjukkan pada gambar 1. Langkah pertama setelah mendapatkan data rekaman suara jantung adalah *preprocessing* dengan cara melakukan *band pass filter* dan normalisasi sinyal suara jantung. Langkah selanjutnya adalah melakukan augmentasi data rekaman suara jantung menggunakan teknik *pitch shifting* dan *time shifting*. Kemudian melakukan ekstraksi fitur untuk mendapatkan hasil spektogram menggunakan transformasi FFT (*Fast Fourier Transform*). Setelah itu dilanjutkan dengan pembangunan model CNN. Kemudian melakukan validasi model menggunakan validasi silang *k-Fold*. Dan langkah yang terakhir adalah melakukan evaluasi dan visualisasi model menggunakan *confusion matrix*.



Gambar 1. Kerangka Berpikir

Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari laman *Kaggle.com* dengan nama *Heartbeat Sounds*. Dataset tersebut terdiri atas file audio berformat .wav yang merekam suara jantung pada berbagai kondisi. Pada dataset tersebut tersedia 2 dataset yang bisa digunakan. Dataset pertama, bernama A, terdiri dari data yang direkam menggunakan aplikasi *iStethoscope Pro* yang ada pada *iPhone*. Perekaman pada dataset A dilakukan secara mandiri oleh masyarakat umum pengguna aplikasi tersebut. Dataset kedua, bernama B, merupakan data yang direkam dari uji klinis di rumah sakit menggunakan stetoskop digital. Panjang file audio pada kedua dataset bervariasi antara 1 sampai 30 detik. Pada dataset A terdapat 4 kategori, yaitu: normal, murmur, *extrahls*, dan *artifact*. Sedangkan pada dataset B terdapat 3 kategori: normal, murmur, dan *extrastole*. Dalam penelitian ini, dataset yang digunakan hanya dataset A dan hanya menggunakan data yang berlabel normal dan murmur saja. Hal ini dilakukan karena dataset A memiliki jumlah distribusi label normal dan murmur yang seimbang.

Tabel 1. Jumlah Data pada Dataset A dan B

Dataset A		Dataset B	
Kategori	Jumlah Data	Kategori	Jumlah Data
Normal	31	Normal	320
Murmur	34	Murmur	95
<i>Extrahls</i>	19	<i>Extrastole</i>	46
<i>Artifact</i>	40	Tidak Berlabel	195
Tidak Berlabel	52		

Preprocessing

Tahapan *preprocessing* bertujuan untuk mempersiapkan sinyal suara jantung agar dapat diolah secara konsisten. Langkah - langkah *preprocessing* meliputi:

- *Band Pass Filter*

Rekaman suara jantung di-*filter* menggunakan *filter butterworth* orde 4 pada rentang frekuensi 30 – 150 Hz. *Filter* ini digunakan untuk mempertahankan rentang frekuensi yang relevan dengan aktivitas jantung, sekaligus mereduksi *noise* rendah dan tinggi.

- Normalisasi

Sinyal hasil *filter* dinormalisasi agar memiliki panjang seragam sebanyak 2000 sampel. Hal ini untuk memudahkan ekstraksi fitur dan proses pelatihan model.

Augmentasi Data


Augmentasi dilakukan pada sinyal domain waktu untuk meningkatkan variasi data dan kemampuan generalisasi model. Hasil augmentasi kemudian digunakan sebagai tambahan data pelatihan dengan label sama seperti data asli. Augmentasi data dilakukan dengan teknik *Pitch Shifting*, yaitu dengan menggeser *pitch* sinyal sebesar 2 *semitone*.

Ekstraksi Fitur

Proses ekstraksi fitur dilakukan untuk memperoleh representasi ciri khas sinyal suara jantung dalam domain frekuensi. Fitur diekstrak dengan transformasi FFT dari domain waktu ke domain frekuensi pada sinyal hasil augmentasi dan sinyal asli. Magnitudo FFT dipangkas pada 1.000 komponen pertama untuk mereduksi dimensi data, representasi ini mencerminkan distribusi frekuensi dari suara jantung. Transformasi ini juga menghasilkan spektogram yang digunakan untuk keperluan visualisasi dan analisis distribusi sinyal dalam domain frekuensi.

Pembentukan Dataset

Dataset akhir terdiri dari hasil ekstraksi fitur data asli dan data augmentasi yang diberi label sesuai sumbernya. Seluruh data disusun dalam *array* tiga dimensi untuk *input* CNN. Meskipun CNN yang digunakan merupakan CNN satu dimensi, data masukan tetap harus disusun dalam *array* tiga dimensi. Dikarenakan persyaratan dari arsitektur *deep learning* pada pustaka TensorFlow dan Keras yang memerlukan *input tensor* dengan format *array* tiga dimensi. dan juga untuk memastikan kompatibilitas data masukan dengan layer konvolusi yang tersedia dalam pustaka TensorFlow dan Keras. Pada gambar 2 ditunjukkan struktur *input tensor* memiliki bentuk: (*samples, timesteps, channels*). Dalam penelitian ini, *samples* adalah jumlah rekaman suara jantung, *timesteps* adalah panjang fitur (pada penelitian ini menggunakan 1.000 titik data hasil FFT), dan *channels* adalah jumlah saluran per *timestep* (pada penelitian ini hanya terdapat 1 saluran).




Gambar 2. Struktur *input* Tensor pada *Layer* Conv1D

Model CNN

Metode yang digunakan pada penelitian ini adalah CNN 1D dengan model seperti yang ditunjukkan pada gambar 3 dan arsitektur sebagai berikut:

- *Input layer*
Menerima vektor fitur FFT berdimensi 1000.
- *Conv1D Layer*
Layer konvolusi satu dimensi dengan 16 *filter*, 3 *kernel size*, dan aktivasi ReLU.
- *MaxPooling1D*
Pooling dengan ukuran 2 untuk reduksi dimensi.
- *Flatten Layer*
Transformasi *output* konvolusi menjadi vektor satu dimensi.
- *Dense Layer*
Hidden layer dengan 64 neuron dan aktivasi ReLU.
- *Dropout*
Regularisasi dengan *dropout rate* 0.5 untuk mencegah *overfitting*.
- *Output Layer*
Dense layer dengan 2 neuron dan aktivasi Softmax untuk klasifikasi dua kelas.



Gambar 3. Model CNN yang Digunakan

Pelatihan dan Validasi Model

Proses pelatihan dilakukan dengan validasi silang *k-fold* ($k = 5$). Data dibagi menjadi 5 *fold* dengan jumlah data yang kurang lebih sama. Dimana pada setiap pelatihan, 1 *fold* digunakan sebagai data uji/validasi dan 4 *fold* lainnya sebagai data latih. Pelatihan diulang sebanyak 5 kali dengan setiap *fold* bergantian menjadi data uji. Sehingga pada setiap pelatihan menggunakan data latih dan data validasi yang berbeda. Parameter pelatihan yang digunakan sebagai berikut:

- *Epoch*: 10
- *Batch size*: 16

- *Optimizer*: Adam
- *Loss function*: Sparse Categorical Crossentropy


Evaluasi dan Visualisasi Model

Evaluasi dilakukan untuk menguji seberapa baik model dalam mengklasifikasi suara jantung. Model dievaluasi pada setiap *fold* dengan mencari nilai akurasi, *precision*, *recall*, dan F1-score. Kemudian hasil evaluasi direkap dan dirata-rata untuk mengetahui performa umum model. Selain itu, visualisasi berupa *waveform* sebelum dan sesudah *band pass filter*, *waveform* sebelum dan sesudah *pitch shifting*, hasil spektogram, dan *confusion matrix* turut disajikan untuk mendukung pemahaman tentang performa model.

HASIL DAN PEMBAHASAN

Filtering Sinyal Suara Jantung

Filtering dilakukan menggunakan *band pass filter* Butterworth orde 4 dengan rentang frekuensi 30 - 150 Hz, bertujuan untuk menghilangkan *noise* di luar rentang relevan suara jantung.



Gambar 4. Bentuk Gelombang Suara Jantung Sebelum dan Setelah *Band Pass Filter*


Gambar 4 menunjukkan bahwa sebelum *band pass filter*, amplitudo gelombang lebih besar dan bervariasi dengan nilai puncak mendekati 0,2 pada suara jantung normal dan 0,6 pada suara jantung murmur. Setelah dilakukan *band pass filter* terlihat amplitudo puncak berkurang sekitar 0,1 pada suara jantung normal dan 0,2 pada suara jantung murmur. Penurunan amplitudo ini dikarenakan komponen frekuensi di luar rentang 30 – 150 Hz dihilangkan.

Selain itu, sebelum *band pass filter*, bentuk gelombang memiliki lebih banyak fluktuasi kecil di antara puncak-puncak utama, yang bisa disebabkan dari *noise* lingkungan atau komponen artefak rekaman. Setelah dilakukan *band pass filter*, bentuk gelombang menjadi lebih “bersih” dengan puncak - puncak utama yang lebih jelas dan penekanan fluktuasi amplitudo di sela - selanya. Hal ini menunjukkan bahwa *band pass filter* efektif mengurangi amplitudo *noise* di luar rentang frekuensi target dan dapat mempertahankan komponen fundamental suara jantung. Kemudian, juga dapat

Meningkatkan kualitas gelombang dengan menghilangkan komponen frekuensi rendah (suara nafas) dan frekuensi tinggi (*noise* lingkungan).

Augmentasi Data

Augmentasi data dilakukan dengan teknik *pitch shifting* sebanyak 2 *semitone* untuk meningkatkan variasi data dan kemampuan generalisasi model. Gambar 5 menunjukkan bentuk gelombang sebelum dan setelah *pitch shifting*. Perubahan terlihat pada bentuk dan amplitudo gelombang. Proses augmentasi data melalui *pitch shifting* terbukti efektif dalam meningkatkan variasi data tanpa kehilangan informasi penting dari gelombang suara jantung.




Gambar 5. Bentuk Gelombang Suara Jantung Sebelum dan Setelah *Pitch Shifting*

Ekstraksi Fitur

Magnitudo FFT


Magnitudo FFT mengilustrasikan perbedaan signifikan antara gelombang suara jantung normal dan murmur. Suara normal menampilkan distribusi lebih luas dengan puncak energi pada frekuensi 50 – 200 Hz. Sedangkan, Suara murmur memiliki puncak amplitudo tinggi pada rentang frekuensi rendah (<100 Hz).



Gambar 6. Magnitudo FFT Suara Jantung

Spektrogram

Spektrogram menunjukkan distribusi energi terhadap waktu dan frekuensi. Setelah *pitch shifting*, terlihat pergeseran komponen frekuensi ke arah yang lebih tinggi (Gambar 7a dan 7b).



Spektrogram sebelum *pitch shifting* didominasi energi pada frekuensi rendah (<300 Hz). Setelah *pitch shifting*, energi bergeser ke frekuensi yang lebih tinggi (~250–500 Hz). Pergeseran ini menciptakan variasi tambahan dalam dataset, mendukung model CNN agar lebih general terhadap variasi suara jantung.


Hasil Evaluasi Model

Model CNN dievaluasi menggunakan validasi silang sebanyak 5 *fold*. Rata – rata akurasi yang diperoleh dari seluruh *fold* adalah 0,7615 dengan rincian metrik sebagai berikut:

Tabel 2. Hasil Rata – Rata Evaluasi Performa Model CNN dari Seluruh Fold


Metrik	Nilai Rata – Rata
Akurasi	0,7615
<i>Precision</i>	0,8533
<i>Recall</i>	0,6912
F1 Score	0,7517

Confusion matrix rata-rata dari seluruh *fold* ditampilkan pada gambar 8 berikut:



Klasifikasi Suara Jantung Menggunakan *Convolutional Neural Network* 1 Dimensi (CNN 1D) dengan *Pitch Shifting* dan Transformasi FFT pada Dataset Terbatas

Setiap *fold* pelatihan menghasilkan grafik akurasi per *epoch* yang disimpan secara otomatis. Grafik akurasi dan *loss* pada semua *fold* ditampilkan pada gambar 9.



Gambar 9. Grafik Akurasi dan *Loss* per *Epoch* pada Semua *Fold*

Hasil rata-rata akurasi sebesar 0,7615 menunjukkan bahwa model CNN 1D cukup efektif dalam membedakan suara jantung normal dan murmur, meskipun akurasi masih dapat ditingkatkan. Jumlah data yang terbatas dan ketidakseimbangan label masih menjadi tantangan utama. Teknik augmentasi dan strategi *preprocessing* perlu dioptimalkan lebih lanjut agar model mampu mengenali variasi gelombang yang lebih kompleks.

KESIMPULAN

Penelitian ini telah berhasil mengembangkan sistem klasifikasi suara jantung menggunakan metode *Convolutional Neural Network* (CNN) satu dimensi dengan pendekatan *preprocessing* berbasis *filtering* dan augmentasi. Berdasarkan tahapan analisis dan hasil evaluasi performa, beberapa kesimpulan yang dapat diambil adalah sebagai berikut:

- Metode *preprocessing* berupa *band pass filter* Butterworth pada rentang 30–150 Hz secara efektif mengurangi *noise* di luar rentang frekuensi utama detak jantung, sehingga menghasilkan sinyal yang lebih bersih dan relevan untuk proses ekstraksi fitur.
- Augmentasi data melalui teknik *pitch shifting* (+2 semitone) terbukti mampu meningkatkan keragaman dataset tanpa menghilangkan karakteristik penting dari gelombang suara jantung. Hal ini mendukung generalisasi model dalam mengenali variasi gelombang suara jantung.
- Transformasi FFT memberikan representasi domain frekuensi yang mampu membedakan karakteristik antara suara jantung normal dan murmur. Spektrum frekuensi dari suara normal memiliki distribusi yang lebih menyebar dibandingkan suara murmur, yang terfokus pada frekuensi rendah.

- Evaluasi spektrogram memperlihatkan bahwa *pitch shifting* turut menggeser distribusi energi frekuensi ke arah yang lebih tinggi, yang secara visual memperkaya fitur spektral dan memperluas cakupan pembelajaran model.
- Model CNN 1D yang diterapkan menunjukkan kinerja klasifikasi yang baik, dengan rata-rata akurasi sebesar 0,7615 berdasarkan validasi silang 5 *fold*. Hasil ini mencerminkan kemampuan model dalam membedakan antara suara jantung normal dan murmur.

Secara keseluruhan, pendekatan yang diterapkan dalam penelitian ini menunjukkan bahwa kombinasi *preprocessing* sinyal, augmentasi data, dan CNN satu dimensi dapat menjadi metode yang efektif dalam pengklasifikasian suara jantung. Hasil ini memberikan kontribusi terhadap pengembangan sistem berbasis kecerdasan buatan untuk deteksi awal gangguan kardiovaskular melalui analisis phonocardiogram (PCG).

DAFTAR PUSTAKA

- Alrabie, S., & Barnawi, A. (2023). HeartWave: A Multiclass Dataset of Heart Sounds for Cardiovascular Diseases Detection. *IEEE Access*, 11, 118722–118736. <https://doi.org/10.1109/ACCESS.2023.3325749>
- Benson, G., Sidebottom, A. J., VanWormer, J. J., Boucher, J. L., Stephens, C., & Krikava, J. (2013). HeartBeat Connections: A Rural Community of Solution for Cardiovascular Health. In *The Journal of the American Board of Family Medicine*. <https://doi.org/10.3122/jabfm.2013.03.120240>
- Chen, T.-E., Yang, S.-I., Ho, L.-T., Tsai, K.-H., Chen, Y.-H., Chang, Y.-F., Lai, Y.-H., Wang, S.-S., Tsao, Y., & Wu, C.-C. (2017). S1 and S2 Heart Sound Recognition Using Deep Neural Networks. *IEEE Transactions on Biomedical Engineering*, 64(2), 372–380. <https://doi.org/10.1109/TBME.2016.2559800>
- Huffman, M. D., Prabhakaran, D., Osmond, C., Fall, C., Tandon, N., Ramakrishnan, L., Ramji, S., Khalil, A., Gera, T., Prabhakaran, P., Biswas, S., Reddy, K. S., Bhargava, S. K., & Sachdev, H. S. (2011). Incidence of Cardiovascular Risk Factors in an Indian Urban Cohort. In *Journal of the American College of Cardiology*. <https://doi.org/10.1016/j.jacc.2010.09.083>
- Jafari, N., Alivand, S., Molaei, H., Rabori, V. S., Asadian, A., Abbasian, S., & Faramarzadeh, R. (2023). How Lifestyle Factors Can Contribute to Cardiovascular Disease Incidence; A Review Study. In *Journal of Preventive Epidemiology*. <https://doi.org/10.34172/jpe.2023.35232>
- Kim, S., Mesquita, F., & Hochman-Mendez, C. (2023). New Biomarkers for Cardiovascular Disease. In *Texas Heart Institute Journal*. <https://doi.org/10.14503/thij-23-8178>
- Qu, M., Chen, X., Yang, D., Li, D., Zhu, K., Guo, X., & Xie, J. (2021). Monitoring of Physiological Sounds With Wearable Device Based on Piezoelectric MEMS Acoustic Sensor. In *Journal of Micromechanics and Microengineering*. <https://doi.org/10.1088/1361-6439/ac371e>

- Talal, M., Aziz, S., Khan, M. U., Ghadi, Y. Y., Naqvi, S. Z. H., & Faraz, M. (2023). Machine Learning-based Classification of Multiple Heart Disorders From PCG Signals. In *Expert Systems*. <https://doi.org/10.1111/exsy.13411>
- Wang, Y., & Denton, K. M. (2024). Special Issue “Sympathetic Nerves and Cardiovascular Diseases.” In *International Journal of Molecular Sciences*. <https://doi.org/10.3390/ijms25052633>
- Weisman, S. M., Garbani, N., & Manganaro, A. (2015). Community-Based Cardiovascular Screening: Detection of Disease in Individuals With No Self-Reported Risk Factors. In *Open Journal of Preventive Medicine*. <https://doi.org/10.4236/ojpm.2015.52009>