

Comparison of Cox Proportional Hazards and Weibull Regression Models in Survival Analysis of Heart Failure Patients Using UCI Repository Data

Ardicha Appu Sianturi¹, Risca Octaviyani Hutapea², May Rani Tabitha Sinaga³

^{1,2,3}Universitas Negeri Medan, Indonesia

Email: ardichasianturi@gmail.com; riscaoctaviyanihutapea@gmail.com; mayrani1805@gmail.com

ABSTRAK

Penyakit gagal jantung merupakan salah satu penyebab utama kematian di seluruh dunia dengan angka mortalitas tinggi akibat penurunan fungsi jantung dan komplikasi sistemik. Analisis survival digunakan untuk memahami faktor-faktor yang memengaruhi ketahanan hidup pasien serta memperkirakan risiko kematian berdasarkan karakteristik klinis. Penelitian ini bertujuan menganalisis faktor-faktor yang memengaruhi waktu ketahanan hidup pasien gagal jantung dan membandingkan kinerja model Cox Proportional Hazards (CoxPH) dengan Weibull Accelerated Failure Time (AFT) dalam memprediksi risiko kematian. Data berasal dari Heart Failure Clinical Records Dataset (UCI Repository) yang mencakup 299 pasien dengan variabel seperti usia, anemia, hipertensi, kadar kreatinin serum, dan fraksi ejeksi. Analisis dilakukan menggunakan metode Kaplan–Meier, CoxPH, dan Weibull AFT dengan evaluasi melalui nilai AIC dan C-index. Hasil menunjukkan bahwa usia, anemia, hipertensi, dan kreatinin meningkatkan risiko kematian, sedangkan fraksi ejeksi bersifat protektif. Model CoxPH memberikan performa terbaik (AIC 958,46; C-index 0,741) dibandingkan Weibull AFT (AIC 1282,24; C-index 0,259). Dengan demikian, CoxPH direkomendasikan untuk estimasi risiko relatif antar pasien, sedangkan Weibull AFT lebih sesuai untuk memperkirakan durasi bertahan hidup absolut.

Keyword: Gagal Jantung; Analisis Survival; Cox Proportional Hazards; Weibull AFT; Prediksi Risiko

ABSTRACT

Heart failure is a leading cause of death worldwide, with a high mortality rate due to decreased heart function and systemic complications. Survival analysis is used to understand factors that influence patient survival and estimate the risk of death based on clinical characteristics. This study aims to analyze factors that influence survival time in heart failure patients and compare the performance of the Cox Proportional Hazards (CoxPH) model with the Weibull Accelerated Failure Time (AFT) in predicting the risk of death. Data are from the Heart Failure Clinical Records Dataset (UCI Repository) which includes 299 patients with variables such as age, anemia, hypertension, serum creatinine levels, and ejection fraction. The analysis was performed using the Kaplan–Meier, CoxPH, and Weibull AFT methods with evaluation through AIC and C-index values. The results show that age, anemia, hypertension, and creatinine increase the risk of death, while ejection fraction is protective. The CoxPH model performed better (AIC 958.46; C-index 0.741) than the Weibull AFT (AIC 1282.24; C-index 0.259). Therefore, CoxPH is recommended for estimating relative risk between patients, while Weibull AFT is more suitable for estimating absolute survival duration.

Keyword: Heart Failure; Survival Analysis; Cox Proportional Hazards; Weibull AFT; Risk Prediction

Corresponding Author:

Ardicha Appu Sianturi,
Universitas Negeri Medan,
Jl. William Iskandar Ps. V, Kenangan Baru, Kec. Percut Sei Tuan,
Kabupaten Deli Serdang, Sumatera Utara 20221, Indonesia
Email: ardichasianturi@gmail.com



1. INTRODUCTION

Penyakit kardiovaskular merupakan penyebab utama kematian di seluruh dunia, dengan gagal jantung menjadi salah satu komplikasi paling serius yang berkontribusi pada tingginya angka mortalitas global. Menurut *WHO*, sekitar 17,9 juta orang meninggal setiap tahunnya akibat penyakit kardiovaskular, mencakup hampir 31% dari total kematian global. Kondisi gagal jantung menyebabkan morbiditas tinggi, menurunkan kualitas hidup pasien, serta meningkatkan beban biaya kesehatan, sehingga perlu mendapatkan perhatian khusus dalam penelitian epidemiologi klinis (Rahmika Alya et al., 2025).

Dalam upaya memahami faktor risiko dan prognosis gagal jantung, analisis *survival* menjadi pendekatan statistik yang penting. Analisis *survival* memungkinkan peneliti memperkirakan peluang bertahan hidup pasien berdasarkan waktu dan mengidentifikasi faktor-faktor yang berpengaruh terhadap risiko kematian. Studi *ATTICA* di Yunani, misalnya, membandingkan model *Cox Proportional Hazards* dengan model parametrik seperti *Weibull*, dan menunjukkan bahwa model parametrik dapat memberikan kinerja yang lebih baik dalam prediksi risiko penyakit kardiovaskular berdasarkan kriteria *Bayesian Information Criterion (BIC)* (Georgouspoulou et al., 2015).

Di Indonesia, penelitian mengenai gagal jantung dengan pendekatan *survival analysis* masih relatif terbatas, meskipun beberapa studi terbaru mulai menggunakan model *Cox Proportional Hazards* maupun *Weibull Regression*. Penelitian oleh Rahmika Alya et al. (2025) menggunakan data sekunder dari *Kaggle* untuk menganalisis pasien gagal jantung dan menemukan bahwa hipertensi menjadi faktor dominan yang berpengaruh signifikan terhadap risiko kematian. Studi tersebut juga membandingkan kinerja *Cox PH* dan *Weibull* dengan kriteria *AIC*, dan menyimpulkan bahwa *Cox PH* lebih fleksibel untuk data tersebut.

Namun, meskipun sudah ada penelitian serupa, sebagian besar studi di Indonesia hanya menggunakan salah satu pendekatan model *survival*, sehingga perbandingan sistematis antara model semiparametrik (*Cox PH*) dan parametrik (*Weibull Regression*) masih jarang dilakukan. Padahal, perbandingan langsung antara kedua model ini penting untuk menentukan model yang lebih sesuai dalam konteks klinis pasien gagal jantung. Berdasarkan kondisi tersebut, penelitian ini merumuskan beberapa permasalahan, yakni bagaimana gambaran karakteristik *survival* pasien gagal jantung berdasarkan data *UCI*, bagaimana hasil pemodelan dengan *Cox Proportional Hazards* dan *Weibull Regression*, serta bagaimana perbandingan kinerja kedua model tersebut berdasarkan kriteria statistik seperti *AIC*, *BIC*, *C-index*, dan *AUC* sehingga dapat ditentukan model yang paling tepat dalam memprediksi *survival* pasien gagal jantung.

Sejalan dengan rumusan masalah tersebut, tujuan penelitian ini adalah untuk mengevaluasi serta membandingkan kinerja model *Cox Proportional Hazards* dan *Weibull Regression* pada analisis *survival* pasien gagal jantung menggunakan data sekunder dari *UCI Repository*. Penelitian ini bertujuan mendeskripsikan karakteristik *survival* pasien, menguji faktor-faktor yang berpengaruh signifikan terhadap risiko kematian, serta menilai performa kedua model dalam memprediksi waktu *survival* pasien gagal jantung. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi metodologis dalam bidang statistik melalui perbandingan model parametrik dan semiparametrik, tetapi juga menawarkan implikasi praktis dalam bidang kesehatan.

Manfaat yang diharapkan dari penelitian ini mencakup tiga aspek utama. Secara teoretis, penelitian ini dapat memperkaya literatur mengenai analisis *survival*, khususnya dalam konteks perbandingan antara model *Cox Proportional Hazards* dan *Weibull Regression*. Secara praktis, hasil penelitian ini diharapkan dapat memberikan wawasan bagi tenaga medis, peneliti kesehatan, maupun pembuat kebijakan mengenai model statistik yang lebih tepat digunakan dalam memprediksi risiko kematian pasien gagal jantung. Sementara itu, secara akademis, penelitian ini diharapkan dapat menjadi referensi bagi penelitian-penelitian selanjutnya yang berfokus pada pengembangan metode analisis *survival* menggunakan data sekunder di bidang kesehatan.

Kaindal dan Venkataramana (2025) melakukan perbandingan antara model *survival* parametrik seperti *Weibull* dan *log-normal* dengan metode *machine learning* terkini dalam memprediksi risiko kematian. Hasil penelitian mereka menunjukkan bahwa meskipun pendekatan berbasis *machine learning* menawarkan fleksibilitas yang lebih besar dalam pemodelan data kompleks, model parametrik tetap memiliki keunggulan dalam hal interpretasi dan kestabilan hasil estimasi. Model *Weibull* secara khusus dinilai efektif untuk data dengan pola *hazard* yang monoton serta tingkat *sensor* yang moderat, sehingga sangat sesuai diterapkan pada kasus klinis seperti pasien gagal jantung. Temuan ini memperkuat alasan penggunaan kombinasi model *Cox Proportional Hazards* dan *Weibull Regression* dalam analisis *survival* modern guna mencapai keseimbangan antara ketepatan prediksi dan kemudahan interpretasi.

2. LITERATURE REVIEW

Analisis *survival* merupakan cabang statistik yang berfokus pada pengkajian waktu hingga terjadinya suatu peristiwa tertentu (*time-to-event*), misalnya kematian, kekambuhan penyakit, atau kesembuhan pasien. Berbeda dari regresi konvensional, pendekatan ini tidak hanya memperhitungkan hubungan variabel tetapi juga

durasi menuju kejadian serta memungkinkan adanya data tersensor (*censoring*). Salah satu komponen utama adalah fungsi *survival* $S(t) = P(T > t)$, yang merepresentasikan probabilitas seorang individu tetap bertahan melewati waktu t . Nilai fungsi ini akan menurun secara monoton dari 1 menuju 0 seiring bertambahnya waktu pengamatan. Selain itu, terdapat fungsi *hazard* $h(t) = f(t) / S(t)$, yang menggambarkan risiko instan terjadinya peristiwa pada waktu t , dengan ketentuan individu masih bertahan sampai waktu tersebut. Kekhasan lain dari analisis ini ialah keberadaan *censoring*, khususnya *right-censoring*, yaitu kondisi ketika waktu kejadian tidak sepenuhnya diketahui, misalnya pasien masih hidup hingga akhir periode studi. Metode *survival* dirancang untuk menangani kondisi semacam ini sehingga hasil estimasi tetap akurat.

Model *Cox Proportional Hazards* (Cox PH) yang diperkenalkan oleh Cox pada tahun 1972 merupakan salah satu metode semi-parametrik paling luas digunakan dalam analisis *survival*. Model ini mengekspresikan fungsi *hazard* sebagai:

$$\lambda(t|X) = \lambda_0(t) \exp(\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n), \quad (1)$$

di mana $\lambda_0(t)$ adalah *baseline hazard* yang tidak ditentukan bentuk distribusinya, sedangkan $\exp(\beta)$ diinterpretasikan sebagai *hazard ratio* (HR). Keunggulan utama model ini adalah kemampuannya mengukur pengaruh kovariat terhadap risiko kejadian tanpa memerlukan asumsi distribusi khusus pada waktu kejadian. Meskipun demikian, model ini bergantung pada asumsi penting yaitu *proportional hazards* (PH), yang menyatakan bahwa rasio *hazard* antar kelompok tetap konstan sepanjang waktu pengamatan. Validitas asumsi PH perlu diuji, misalnya dengan *Schoenfeld residuals*, grafik *log-log survival*, atau memasukkan kovariat waktu-bergantung. Jika asumsi ini tidak terpenuhi, interpretasi *hazard ratio* dapat menjadi bias, sehingga diperlukan pendekatan lain seperti stratifikasi atau penggunaan model parametrik.

Weibull Regression merupakan model parametrik yang banyak diterapkan dalam analisis *survival* karena sifatnya yang fleksibel. Fungsi *hazard* pada model ini dikendalikan oleh dua parameter utama, yaitu *shape* (k) dan *scale* (λ), dengan bentuk persamaan:

$$h(t) = \frac{k}{\lambda} \left(\frac{t}{\lambda} \right)^{k-1} \quad (2)$$

Parameter *shape* memiliki arti penting dalam memahami pola risiko: ketika $k > 1$, tingkat *hazard* akan meningkat seiring bertambahnya waktu; bila $k = 1$, *hazard* tetap konstan sebagaimana pada distribusi eksponensial; dan jika $k < 1$, *hazard* cenderung menurun. Keunggulan model ini tidak hanya terletak pada estimasi *hazard ratio*, tetapi juga kemampuannya menghitung ukuran waktu absolut seperti *median survival* atau *event time ratio*. Meski demikian, *Weibull Regression* cukup peka terhadap kesalahan spesifikasi distribusi, sehingga pemeriksaan kesesuaian model perlu dilakukan agar hasil analisis dapat dipercaya sebelum digunakan sebagai dasar pengambilan keputusan.

Li et al. (2024) melakukan analisis *survival* pada pasien kanker endometrium dengan membandingkan model *Cox Proportional Hazards* dan *Weibull Regression*. Temuan mereka menunjukkan bahwa *Weibull* memberikan kecocokan model yang lebih baik berdasarkan nilai *AIC* dan *time-dependent AUC*, khususnya pada kondisi dengan pola *hazard* yang meningkat secara monoton. Di sisi lain, *Cox PH* tetap unggul dalam menghasilkan estimasi *hazard ratio* yang konsisten. Penelitian ini menegaskan bahwa *Weibull* dapat menjadi pelengkap *Cox* karena mampu memberikan informasi tambahan berupa *event time ratio*, sehingga menghasilkan pemahaman yang lebih menyeluruh terhadap data klinis.

Habibi et al. (2018) mengevaluasi kinerja model *survival Cox Proportional Hazards* dan beberapa model parametrik, termasuk *Weibull*, pada pasien kanker lambung. Hasil penelitian menunjukkan bahwa model parametrik secara umum memberikan kecocokan yang lebih baik berdasarkan kriteria *AIC*, dengan *Weibull* dan *log-logistik* menempati posisi terbaik. Meskipun demikian, penulis menekankan pentingnya melakukan validasi eksternal, karena kesesuaian model sangat dipengaruhi oleh distribusi data serta karakteristik populasi pasien. Temuan ini mengindikasikan bahwa model parametrik dapat menjadi pilihan yang layak ketika asumsi *proportional hazards* tidak sepenuhnya terpenuhi.

Montaseri et al. (2025) melakukan studi pada pasien gagal jantung dengan membandingkan model *Cox Proportional Hazards* dan model *survival* parametrik *Weibull*. Penelitian tersebut menemukan bahwa *Weibull* lebih unggul dalam menghasilkan estimasi waktu ketahanan hidup dan *event time ratio*, sedangkan *Cox PH* lebih sesuai ketika tujuan analisis difokuskan pada perbandingan *hazard ratio* antar kelompok. Hasil ini menekankan bahwa pemilihan model *survival* perlu disesuaikan dengan sasaran penelitian, apakah untuk memperkirakan durasi hidup atau mengevaluasi risiko relatif antar kategori pasien.

Ashine et al. (2021) melakukan penelitian terhadap 300 pasien gagal jantung di Ethiopia dengan menggunakan pendekatan *Bayesian Accelerated Failure Time (AFT)* yang memanfaatkan distribusi *Weibull*, *log-logistik*, serta *log-normal*. Hasil analisis menunjukkan bahwa model *log-normal AFT* menghasilkan performa terbaik dengan nilai *Deviance Information Criterion (DIC)* paling rendah dibandingkan model lainnya. Variabel usia, anemia, hipertensi, dan diabetes ditemukan berpengaruh signifikan terhadap penurunan waktu kelangsungan hidup pasien. Temuan tersebut memperkuat pentingnya penggunaan model parametrik

dalam analisis data klinis, khususnya ketika tujuan penelitian berfokus pada estimasi kuantitatif waktu ketahanan hidup pasien.

Moreno-Sánchez (2023) memanfaatkan *dataset UCI Heart Failure Clinical Records* untuk membangun model prediksi *survival* pada pasien gagal jantung. Studi ini menyoroti bahwa meskipun model *Cox Proportional Hazards* dan berbagai metode *machine learning* telah banyak diterapkan, penggunaan model parametrik seperti *Weibull* masih jarang dilakukan. Kondisi ini menunjukkan adanya kesenjangan penelitian yang penting, yaitu perlunya analisis yang secara langsung membandingkan *Cox* dan *Weibull* pada *dataset UCI* agar tersedia bukti empiris yang dapat direplikasi dan dijadikan standar metodologis.

Plana et al. (2022) dalam studi metodologis pada pasien kanker menekankan keunggulan model *Weibull* dalam memberikan estimasi yang lebih presisi, khususnya pada subkelompok kecil dalam uji klinis. Penelitian tersebut menunjukkan bahwa asumsi *proportional hazards* pada model *Cox* sering kali tidak terpenuhi, terutama pada pengobatan modern seperti terapi imun. Dalam kondisi semacam ini, *Weibull* menjadi pilihan yang lebih stabil berkat fleksibilitasnya dalam menangkap pola *hazard* yang dapat meningkat maupun menurun seiring berjalannya waktu.

Giolo et al. (2012) menganalisis data pasien gagal jantung menggunakan model *Cox Proportional Hazards* dan menemukan bahwa beberapa kovariat menunjukkan efek yang berubah seiring waktu (*time-varying effect*), sehingga asumsi *proportional hazards* tidak sepenuhnya terpenuhi. Hasil ini menegaskan bahwa model *Cox PH* tidak selalu menjadi pilihan yang optimal di setiap kondisi, serta membuka peluang bagi penggunaan model parametrik seperti *Weibull* sebagai alternatif ketika pelanggaran asumsi tersebut muncul dalam data klinis.

Walaupun perbandingan antara *Cox Proportional Hazards (Cox PH)* dan *Weibull Regression* telah banyak dilakukan dalam berbagai penelitian klinis, kajian yang secara khusus menggunakan *dataset UCI Heart Failure Clinical Records* masih sangat terbatas. Sebagian besar studi terdahulu memanfaatkan data rumah sakit atau kohort lokal, sedangkan *dataset UCI* yang memuat informasi 299 pasien gagal jantung lebih sering digunakan untuk penelitian prediksi berbasis *machine learning* daripada analisis *survival* komparatif. Kondisi ini menyebabkan belum tercapai kesepakatan mengenai model yang paling sesuai untuk *dataset* tersebut. Selain itu, penelitian yang ada umumnya hanya menampilkan sebagian indikator kinerja, seperti *AIC* atau *C-index*, dan jarang memasukkan evaluasi komprehensif mencakup *time-dependent AUC*, *Brier score*, serta pemeriksaan asumsi *proportional hazards*. Dengan latar belakang tersebut, studi ini dirancang untuk mengisi kekosongan tersebut melalui perbandingan sistematis antara *Cox PH* dan *Weibull Regression* pada *dataset UCI Heart Failure*, sehingga dapat menghasilkan pedoman metodologis yang lebih standar dan mudah direplikasi untuk penelitian serupa.

Voeltz et al. (2024) mengembangkan model *hazard* aditif parametrik untuk menganalisis data *time-to-event*. Dalam model ini, pengaruh kovariat dipetakan langsung pada skala waktu kejadian, sehingga interpretasinya berfokus pada perubahan durasi kejadian alih-alih rasio *hazard*. Penelitian mereka menunjukkan bahwa model aditif parametrik memiliki kinerja yang setara dengan model *Cox*, namun menawarkan kemudahan dalam perhitungan fungsi *hazard* maupun *survival* secara eksplisit. Pendekatan ini memberikan manfaat praktis bagi peneliti yang ingin menggambarkan pengaruh variabel klinis terhadap perubahan waktu terjadinya suatu peristiwa secara lebih konkret.

3. RESEARCH METHOD

A. Data Penelitian

Penelitian ini menggunakan data sekunder dari *Heart Failure Clinical Records Dataset* yang tersedia pada *UCI Machine Learning Repository* (<https://doi.org/10.24432/C5Z89R>). *Dataset* ini terdiri dari 299 pasien gagal jantung yang dikumpulkan dari rekam medis rumah sakit dengan informasi demografis, klinis, serta *outcome survival*. *Dataset* ini juga telah digunakan dalam beberapa penelitian sebelumnya untuk analisis *survival* pada pasien gagal jantung (Rahmika Alya et al., 2025).

Variabel penelitian dibagi menjadi tiga kategori utama, yaitu variabel demografis, variabel klinis, serta variabel *survival*. Rincian variabel ditampilkan pada Tabel dibawah ini:

Tabel 1. Definisi Variabel Penelitian

Kategori Variabel	Nama Variabel	Tipe Data	Keterangan
Demografis	age	Numerik	Usia pasien (tahun)
	sex	Kategorik	Jenis kelamin (1 = laki-laki, 0 = perempuan)
	smoking	Kategorik	Status merokok (1 = merokok, 0 = tidak)
	diabetes	Kategorik	Status diabetes (1 = ya, 0 = tidak)
	anaemia	Kategorik	Status anemia (1 = ya, 0 = tidak)
	high_blood_pressure	Kategorik	Riwayat hipertensi (1 = ya, 0 = tidak)
Klinis	serum_creatinine	Numerik	Kadar kreatinin serum (mg/dL)

Kategori Variabel	Nama Variabel	Tipe Data	Keterangan
Survival	serum_sodium	Numerik	Kadar natrium serum (mEq/L)
	platelets	Numerik	Jumlah platelet ($kiloplatelet/mL$)
	creatinine_phosphokinase	Numerik	Kadar CPK (mcg/L)
	ejection_fraction	Numerik	Fraksi ejeksi jantung (%)
	time	Numerik	Lama follow-up (hari)
	DEATH_EVENT	Kategorik	Status kejadian (1 = meninggal, 0 = hidup/censored)

B. Eksplorasi Data

Eksplorasi data dilakukan untuk memperoleh gambaran awal mengenai karakteristik pasien gagal jantung. Analisis deskriptif diterapkan pada variabel numerik melalui perhitungan *mean*, *median*, standar deviasi, nilai minimum, dan maksimum. Untuk variabel kategorik, digunakan tabulasi distribusi frekuensi dan persentase. Tahap ini bertujuan mengidentifikasi pola umum data, mendeteksi kemungkinan pencilan, serta menentukan variabel yang relevan untuk analisis lanjutan (Rahmika Alya et al., 2025).

Selain itu, kurva *Kaplan–Meier* digunakan untuk menggambarkan fungsi *survival* baik secara keseluruhan maupun berdasarkan kelompok kovariat tertentu, seperti hipertensi, anemia, atau fraksi ejeksi jantung. Hasil eksplorasi ini menjadi dasar pemilihan variabel yang akan dimasukkan ke dalam model *Cox Proportional Hazards* dan *Weibull Regression*.

C. Pemodelan Cox Proportional Hazards

Model *Cox Proportional Hazards* digunakan untuk menganalisis pengaruh variabel kovariat terhadap risiko kematian pasien gagal jantung. Model ini bersifat semi-parametrik karena tidak mengasumsikan bentuk tertentu dari fungsi *baseline hazard* $h_0(t)$.

Secara umum, model Cox dapat dituliskan sebagai berikut:

$$h(t | X) = h_0(t) \exp(\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p) \quad (3)$$

dengan keterangan:

- $h(t|X)$: fungsi *hazard* pada waktu t dengan kovariat X ,
- $h_0(t)$: fungsi *baseline hazard*,
- β_i : koefisien regresi untuk kovariat ke- i ,
- X_i : kovariat ke- i .

Interpretasi parameter β_i dilakukan melalui *Hazard Ratio (HR)* dengan rumus $\exp(\beta_i)$. Nilai $HR > 1$ menunjukkan peningkatan risiko kematian, sedangkan $HR < 1$ menunjukkan penurunan risiko.

Validitas model diuji melalui asumsi *proportional hazards* dengan menggunakan analisis residual, seperti *Schoenfeld residuals*. Penelitian sebelumnya menunjukkan bahwa model Cox efektif digunakan dalam memprediksi *survival* pasien gagal jantung, dengan beberapa faktor klinis seperti usia, hipertensi, dan fraksi ejeksi jantung terbukti signifikan memengaruhi risiko kematian (Rahmika Alya et al., 2025).

D. Pemodelan Weibull Regression

Model *Weibull Regression* digunakan sebagai pendekatan parametrik dalam analisis *survival*. Model ini mengasumsikan bahwa waktu *survival* mengikuti distribusi *Weibull*, yang fleksibel untuk memodelkan *hazard* yang dapat meningkat, menurun, maupun konstan seiring waktu.

Fungsi *hazard* dari distribusi *Weibull* dituliskan sebagai berikut:

$$h(t) = \lambda \gamma t^{\gamma-1} \quad (4)$$

dengan:

- $\lambda > 0$: parameter skala (*scale parameter*),
 - $\gamma > 0$: parameter bentuk (*shape parameter*).
- Bentuk fungsi *hazard* ditentukan oleh nilai γ :
- $\gamma > 1$: *hazard* meningkat seiring waktu,
 - $\gamma < 1$: *hazard* menurun seiring waktu,
 - $\gamma = 1$: *hazard* konstan (setara dengan distribusi eksponensial).

Dalam regresi *Weibull*, kovariat dapat dimasukkan melalui fungsi log-linear sebagai berikut:

$$h(t | X) = \lambda \gamma t^{\gamma-1} \exp(\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p) \quad (5)$$


Estimasi parameter dilakukan menggunakan metode *Maximum Likelihood Estimation (MLE)*, dan interpretasi koefisien β_i dilakukan melalui *Hazard Ratio (HR)* yang diperoleh dari $\exp(\beta_i)$. Dengan pendekatan ini, model *Weibull* tidak hanya mengukur pengaruh kovariat, tetapi juga memberikan informasi tambahan mengenai bentuk *hazard* pasien gagal jantung sehingga mendukung pemahaman terhadap dinamika risiko klinis (Quraissy & Madya, 2021; Rahmika Alya et al., 2025; Yanti & Purnamasari, 2022).

E. Seleksi Kovariat

Seleksi kovariat dilakukan untuk memperoleh model yang sederhana (*parsimonious*) namun tetap akurat. Proses ini menggunakan dua pendekatan:

- 1) Stepwise Selection
 - *Backward elimination*: menghapus variabel tidak signifikan dari model penuh.
 - *Forward selection*: menambahkan variabel secara bertahap berdasarkan tingkat signifikansi.
- 2) Penalized Regression (LASSO)
 - Digunakan jika jumlah kovariat relatif banyak atau terdapat multikolinearitas.
 - Variabel yang tidak relevan dieliminasi dengan menetapkan koefisien = 0.

Kedua pendekatan diterapkan pada model *Cox Proportional Hazards* dan *Weibull Regression* untuk menghasilkan model akhir yang efisien serta valid dalam memprediksi risiko kematian pasien gagal jantung.



Gambar 1. Flowchart Seleksi Kovariat

F. Perbandingan Model

Setelah model *Cox Proportional Hazards* dan *Weibull Regression* dibentuk, langkah selanjutnya adalah melakukan evaluasi kinerja untuk menentukan model yang paling sesuai dalam menganalisis *survival* pasien gagal jantung. Perbandingan kinerja kedua model dilakukan menggunakan beberapa kriteria statistik yang umum digunakan dalam analisis *survival*.

1. Akaike Information Criterion (AIC)

AIC digunakan untuk menilai kesesuaian model dengan memberikan penalti terhadap jumlah parameter yang digunakan. Model dengan nilai *AIC* lebih kecil dianggap memiliki keseimbangan terbaik antara *goodness-of-fit* dan kompleksitas model.

2. Bayesian Information Criterion (BIC)

BIC memiliki prinsip yang sama dengan *AIC*, namun memberikan penalti yang lebih besar terhadap kompleksitas model. Oleh karena itu, *BIC* lebih ketat dalam memilih model yang efisien. Model dengan nilai *BIC* lebih kecil dianggap lebih baik.

3. Concordance Index (C-index)

C-index mengukur kemampuan model dalam memprediksi urutan kejadian *survival*. Nilai *C-index* berkisar antara 0,5 (prediksi acak) hingga 1 (prediksi sempurna). Semakin tinggi nilai *C-index*, semakin baik kemampuan diskriminasi model dalam memprediksi kejadian (Rahmika Alya et al., 2025).

4. Time-dependent Area Under the Curve (AUC)

AUC digunakan untuk menilai performa diskriminasi model pada berbagai titik waktu. Nilai *AUC* yang lebih tinggi menunjukkan akurasi prediksi yang lebih baik. Evaluasi *AUC* ini menjadi penting terutama ketika model digunakan untuk prediksi jangka panjang maupun jangka pendek (Cavalcante et al., 2023).

Perbandingan model dilakukan dengan menampilkan seluruh kriteria tersebut secara simultan. Model dengan nilai *AIC* dan *BIC* yang lebih kecil, serta nilai *C-index* dan *AUC* yang lebih tinggi, akan dipilih sebagai model yang paling unggul dalam memprediksi *survival* pasien gagal jantung.

Lee et al. (2025) menggunakan model *time-to-event* berbasis parametrik untuk memprediksi respons terapi obat antikanker dengan memanfaatkan distribusi *Weibull* dalam memperkirakan waktu progresi penyakit. Hasil penelitian menunjukkan bahwa model parametrik tidak hanya unggul dalam memprediksi risiko kejadian, tetapi juga mampu memberikan estimasi langsung terhadap waktu terjadinya peristiwa medis. Keunggulan tersebut menjadikan pendekatan *Weibull AFT* relevan untuk diterapkan di berbagai bidang kedokteran, termasuk kardiologi, karena dapat menghasilkan estimasi durasi hidup pasien yang lebih akurat dan realistis.

G. Perangkat Lunak

Analisis data pada penelitian ini dilakukan menggunakan perangkat lunak *Python*, karena memiliki pustaka (*library*) yang kuat dan banyak digunakan dalam analisis *survival*. Beberapa *library* utama yang digunakan adalah:

- *lifelines*: untuk pemodelan *Cox Proportional Hazards* dan *Weibull Regression*, serta estimasi *Kaplan–Meier curve*.
- *scikit-survival*: untuk perhitungan evaluasi model seperti *C-index* dan *time-dependent AUC*.
- *pandas* dan *numpy*: untuk manajemen dan manipulasi data.

- matplotlib dan seaborn: untuk visualisasi grafik eksplorasi data serta kurva *survival*.

Python dipilih karena bersifat *open-source*, mendukung *reproducibility*, serta memiliki dokumentasi dan komunitas yang luas, sehingga hasil penelitian dapat dengan mudah diuji ulang oleh peneliti lain menggunakan *dataset* yang sama.

4. RESULTS AND DISCUSSION

A. Statistik Deskriptif

Analisis deskriptif dilakukan untuk mengidentifikasi karakteristik dasar pasien gagal jantung. Statistik yang digunakan mencakup ukuran pemusatan (*mean*, *median*), ukuran dispersi (standar deviasi), serta nilai minimum, kuartil, dan maksimum sebagaimana ditunjukkan pada Tabel berikut.


Tabel 2. Statistik Deskriptif

Variabel	n	Mean	Std	Min	25%	50%	75%	Max
age	299	60.83	11.89	40.0	51.0	60.0	70.0	95.0
anaemia	299	0.43	0.50	0.0	0.0	0.0	1.0	1.0
creatinine_phosphokinase	299	581.84	970.29	23.0	116.5	250.0	582.0	7861.0
diabetes	299	0.42	0.49	0.0	0.0	0.0	1.0	1.0
ejection_fraction	299	38.08	11.83	14.0	30.0	38.0	45.0	80.0
high_blood_pressure	299	0.35	0.48	0.0	0.0	0.0	1.0	1.0
platelets	299	263358.03	97804.24	25100.0	212500.0	262000.0	303500.0	850000.0
serum_creatinine	299	1.39	1.03	0.5	0.9	1.1	1.4	9.4
serum_sodium	299	136.63	4.41	113.0	134.0	137.0	140.0	148.0
sex	299	0.65	0.48	0.0	0.0	1.0	1.0	1.0
smoking	299	0.32	0.47	0.0	0.0	0.0	1.0	1.0
time	299	130.26	77.61	4.0	73.0	115.0	203.0	285.0
DEATH_EVENT	299	0.32	0.47	0.0	0.0	0.0	1.0	1.0

Rata-rata usia responden adalah $60,8 \pm 11,9$ tahun (rentang 40–95 tahun) dan sebagian besar berjenis kelamin laki-laki (64,8%). Sekitar 32% pasien meninggal selama masa observasi dengan rata-rata waktu tindak lanjut 130 hari. Penyakit penyerta yang dominan meliputi anemia (43%), diabetes (41,8%), dan hipertensi (35%). Nilai median *ejection fraction* sebesar 38% mencerminkan penurunan fungsi pompa jantung yang bermakna, sedangkan variasi kadar *serum creatinine* (median 1,1 mg/dL) dan *serum sodium* (median 137 mmol/L) menunjukkan adanya perbedaan fungsi ginjal dan keseimbangan elektrolit antarresponden. Temuan ini sejalan dengan hasil penelitian Couissi et al. (2024) yang mengidentifikasi usia lanjut, jenis kelamin laki-laki, hipertensi, anemia, dan *ejection fraction* rendah sebagai prediktor mortalitas utama pada pasien gagal jantung dengan fraksi ejeksi berkurang.

B. Kurva Kaplan–Meier

Analisis *Kaplan–Meier* digunakan untuk menggambarkan estimasi probabilitas *survival* pasien gagal jantung selama periode pengamatan. Sumbu horizontal menunjukkan waktu tindak lanjut (hari), sedangkan sumbu vertikal menunjukkan probabilitas pasien tetap hidup pada waktu tertentu. Area bayangan di sekitar kurva menggambarkan interval kepercayaan 95% dari estimasi *survival*.



Gambar 2. Kurva Kaplan–Meier untuk semua objek

Dari kurva terlihat bahwa probabilitas *survival* mendekati 1,0 pada awal observasi dan menurun tajam hingga sekitar 0,6 pada hari ke-250. Penurunan paling curam terjadi pada 100 hari pertama, menunjukkan bahwa sebagian besar kematian terjadi pada fase awal perawatan. Setelah periode tersebut, kemiringan kurva

menjadi lebih landai, menandakan penurunan risiko kematian yang lebih stabil pada pasien yang bertahan. Secara klinis, pola ini menggambarkan fase risiko tinggi segera setelah diagnosis akibat instabilitas hemodinamik dan gangguan fungsi ginjal. Hasil ini sejalan dengan penelitian Mumbulu et al. (2024) yang melaporkan mortalitas awal tinggi pada pasien gagal jantung akut dengan penyakit ginjal kronik, infeksi, serta kadar *NT-proBNP* > 10.000 ng/mL.

C. Model Cox Proportional Hazards

1) Tabel hasil Cox (HR, p-value, CI):

Analisis menggunakan model *Cox Proportional Hazards* dilakukan untuk mengidentifikasi faktor-faktor yang memengaruhi risiko kematian pada pasien gagal jantung. Nilai *Hazard Ratio* (HR), *p-value*, dan *Confidence Interval* (CI) masing-masing variabel disajikan pada Tabel dibawah ini. Nilai *HR* > 1 menunjukkan peningkatan risiko kematian, sedangkan *HR* < 1 menandakan efek protektif terhadap kelangsungan hidup.

Tabel 3. Hasil Cox

Kovariat	Coef	HR	SE	z	p-value	CI Lower	CI Upper
age	0.046	1.047	0.009	4.98	<0.001	0.028	0.065
anaemia	0.46	1.584	0.217	2.12	0.033	0.035	0.885
creatinine_phosphokinase	0.00022	1.0002	0.0001	2.23	0.026	0.00003	0.00042
diabetes	0.14	1.15	0.223	0.63	0.531	-0.297	0.577
ejection_fraction	-0.049	0.952	0.01	-4.67	<0.001	-0.069	-0.028
high_blood_pressure	0.476	1.609	0.216	2.2	0.028	0.052	0.899
platelets	-4.60E-07	1	0.000001	-0.41	0.681	-3E-06	0.000002
serum_creatinine	0.321	1.379	0.07	4.58	<0.001	0.184	0.459
serum_sodium	-0.044	0.957	0.023	-1.9	0.057	-0.09	0.001
sex	-0.238	0.789	0.252	-0.94	0.345	-0.731	0.256
smoking	0.129	1.138	0.251	0.51	0.608	-0.363	0.621

Faktor-faktor yang berpengaruh signifikan terhadap peningkatan risiko kematian meliputi usia (HR = 1.047; $p < 0.001$), anemia (HR = 1.584; $p = 0.033$), kadar *creatinine phosphokinase* (HR = 1.0002; $p = 0.026$), hipertensi (HR = 1.609; $p = 0.028$), dan serum kreatinin (HR = 1.379; $p < 0.001$). Sebaliknya, *ejection fraction* menurunkan risiko kematian (HR = 0.952; $p < 0.001$).

Hasil ini menunjukkan bahwa peningkatan usia, disfungsi ginjal, serta tekanan darah tinggi memperburuk prognosis pasien, sedangkan fungsi jantung yang baik berperan protektif terhadap mortalitas. Secara klinis, temuan ini menegaskan bahwa faktor kardiometabolik dan ginjal berkontribusi kuat terhadap durasi ketahanan hidup pasien gagal jantung.

Temuan tersebut konsisten dengan laporan Rahmika Alya et al. (2025) yang menegaskan hipertensi sebagai faktor dominan pada pasien gagal jantung, serta penelitian Montaseri et al. (2025) yang menyimpulkan bahwa model *Cox Proportional Hazards* memberikan estimasi *hazard ratio* yang stabil, akurat, dan interpretatif dalam analisis risiko relatif antar pasien.

2) Hasil Uji Asumsi PH

Tabel 4. Hasil Uji Asumsi

Variabel	p (KM)	p (Rank)	Kesimpulan
age	0.74	0.86	PH terpenuhi
anaemia	1.00	0.93	PH terpenuhi
creatinine_phosphokinase	0.29	0.29	PH terpenuhi
diabetes	0.84	0.99	PH terpenuhi
ejection_fraction	0.02	0.01	PH tidak terpenuhi (melanggar asumsi PH)
high_blood_pressure	0.74	0.74	PH terpenuhi
platelets	0.85	0.74	PH terpenuhi
serum_creatinine	0.07	0.06	Hampir melanggar (mendekati 0,05)
serum_sodium	0.29	0.19	PH terpenuhi
sex	0.76	0.61	PH terpenuhi
smoking	0.45	0.57	PH terpenuhi

Hasil pengujian asumsi *Proportional Hazards* (PH) menggunakan *Schoenfeld residuals* menunjukkan bahwa sebagian besar kovariat memenuhi asumsi PH, kecuali *ejection fraction* yang memiliki nilai $p < 0,05$ baik pada uji *Kaplan–Meier* maupun uji *Rank*. Hal ini mengindikasikan bahwa pengaruh *ejection fraction* terhadap risiko kematian tidak konstan sepanjang waktu, kemungkinan akibat perubahan fungsi pompa jantung selama masa perawatan.

Sementara itu, *serum creatinine* ($p = 0,07$; $0,06$) hampir melanggar asumsi PH, yang mencerminkan adanya dinamika fungsi ginjal yang berubah selama observasi. Kovariat lain seperti usia, anemia, hipertensi, diabetes, kadar natrium serum, dan perilaku merokok memenuhi asumsi PH, sehingga efeknya terhadap risiko kematian dapat dianggap relatif stabil sepanjang waktu.

Temuan ini konsisten dengan hasil penelitian Hamid et al. (2022) dan Ervi Dayana Putri et al. (2025), yang melaporkan bahwa variabel klinis seperti *ejection fraction* sering menunjukkan efek waktu-bergantung (*time-varying effect*) pada pasien gagal jantung, sementara kovariat lain umumnya bersifat proporsional terhadap waktu pengamatan.

D. Weibull Regression

Model *Weibull Accelerated Failure Time (AFT)* digunakan untuk menganalisis faktor-faktor yang memengaruhi lama waktu hingga terjadinya kejadian (*event*) pada pasien gagal jantung. Model ini dipilih karena bersifat fleksibel dalam menggambarkan laju *hazard* yang dapat meningkat, menurun, maupun konstan terhadap waktu (Hasan et al., 2021). Ringkasan hasil estimasi parameter model ditampilkan pada Tabel berikut, yang mencakup nilai koefisien, time ratio, standar error, nilai z, dan p-value untuk masing-masing variabel.

Tabel 5. Model Weibull

Covariate	Coef	Time Ratio	SE(Coef)	z	p-value
age	-0.0497977	0.951422	0.010047	-4.956633	7.17×10^{-7}
anaemia	-0.4998812	0.606603	0.223512	-2.236485	0.025320
creatinine_phosphokinase	-0.000243305	0.999757	0.000104	-2.340884	0.019238
diabetes	-0.1465928	0.863646	0.232032	-0.631779	0.527532
ejection_fraction	0.0524543	1.053854	0.011575	4.531619	5.85×10^{-6}
high_blood_pressure	-0.5144129	0.597852	0.222400	-2.313006	0.020722
platelets	5.511458e-07	1.000001	0.000001	0.466923	0.640555
serum_creatinine	-0.3331508	0.716662	0.073072	-4.559215	5.13×10^{-6}
serum_sodium	0.04499511	1.046023	0.024125	1.865108	0.062166
sex	0.2456910	1.278504	0.262881	0.934608	0.349991
smoking	-0.1186956	0.888078	0.261085	-0.454624	0.649379
Intercept	1.992318	7.332508	3.291458	0.605299	0.544980
rho Intercept	-0.03796329	0.962748	0.088821	-0.427413	0.669079

Hasil pemodelan menunjukkan bahwa beberapa variabel berpengaruh signifikan terhadap waktu *survival* pasien gagal jantung. Koefisien negatif dengan *time ratio* < 1 menunjukkan percepatan kejadian (waktu *survival* lebih pendek), sedangkan koefisien positif dengan *time ratio* > 1 menunjukkan pemanjangan waktu *survival*.

Variabel usia ($\beta = -0,0498$; $p < 0,001$) memperpendek waktu *survival* sekitar 5% setiap penambahan satu tahun usia. Anemia (*time ratio* = 0,61; $p = 0,025$) mengurangi waktu *survival* sebesar 39%, dan *creatinine phosphokinase* ($p = 0,019$) juga berkontribusi terhadap percepatan kejadian. Sebaliknya, *ejection fraction* ($\beta = 0,0524$; $p < 0,001$) berhubungan dengan peningkatan waktu *survival* sekitar 5% untuk setiap kenaikan 1% nilai fraksi ejeksi, menunjukkan efek protektif terhadap mortalitas. Variabel hipertensi (*time ratio* = 0,59; $p = 0,020$) dan serum kreatinin (*time ratio* = 0,71; $p < 0,001$) memiliki pengaruh negatif yang signifikan terhadap waktu *survival*.

Sementara itu, diabetes, platelet, serum sodium, jenis kelamin, dan kebiasaan merokok tidak berpengaruh signifikan ($p > 0,05$). Nilai parameter bentuk *Weibull* ($\rho \approx 0,96$) menunjukkan laju *hazard* yang relatif konstan selama periode pengamatan. Hasil ini sejalan dengan penelitian Hasan et al. (2021) yang menunjukkan efektivitas model *Weibull* dalam mengidentifikasi faktor signifikan terhadap waktu kejadian klinis, serta Dewi Lukitasari et al. (2015) yang menemukan bahwa usia dan kondisi klinis utama merupakan prediktor penting dalam memendekkan waktu *survival* pasien penyakit kardiovaskular.

Dengan demikian, dapat disimpulkan bahwa variabel usia, anemia, kadar *creatinine phosphokinase*, hipertensi, dan serum kreatinin mempercepat terjadinya kejadian (memperpendek *survival*), sedangkan fraksi ejeksi memperpanjang waktu *survival* pasien gagal jantung.

E. Model Terbaik

Tabel 6. Perbandingan Model

Model	AIC	C-index
CoxPH	958.455735	0.740805
Weibull AFT	1282.235598	0.259435

Perbandingan nilai *Akaike Information Criterion (AIC)* dan *Concordance Index (C-index)* menunjukkan bahwa model *Cox Proportional Hazards (CoxPH)* memiliki kinerja terbaik dibanding *Weibull Accelerated Failure Time (AFT)*. Model *CoxPH* menghasilkan nilai *AIC* lebih rendah (958,46) dan *C-index* lebih tinggi (0,74) dibanding *Weibull* (*AIC* = 1282,24; *C-index* = 0,26), menandakan kemampuan diskriminasi dan *goodness-of-fit* yang lebih baik.

Dengan demikian, model *CoxPH* lebih sesuai digunakan pada *dataset* ini untuk menggambarkan hubungan antara kovariat dan risiko kematian pasien gagal jantung. Hasil ini sejalan dengan temuan Damayanti et al. (2024) yang melaporkan bahwa *CoxPH* memiliki *AIC* lebih rendah dibanding *Weibull* pada data pasien COVID-19, serta didukung oleh Moreno-Sánchez (2023) yang menegaskan keunggulan *CoxPH* dalam

memprediksi *survival* pasien gagal jantung dibanding model parametrik, meskipun model *Weibull* tetap berguna untuk menafsirkan *time ratio* secara klinis.

F. Kelebihan dan Kekurangan Model

Model *Cox Proportional Hazards (CoxPH)* bersifat semi-parametrik, karena tidak memerlukan bentuk distribusi *hazard* dasar. Kelebihannya adalah fleksibel, stabil pada berbagai jenis data, dan mudah diinterpretasikan melalui *Hazard Ratio (HR)*. Namun, model ini sangat bergantung pada asumsi *Proportional Hazards (PH)*; bila asumsi tersebut dilanggar, estimasi dapat menjadi bias dan memerlukan modifikasi seperti penambahan *time-varying covariates* atau stratifikasi (Sarumpaet et al., 2024).

Sebaliknya, model *Weibull Accelerated Failure Time (AFT)* merupakan model parametrik penuh yang mengasumsikan waktu *survival* mengikuti distribusi *Weibull*. Kelebihannya terletak pada efisiensi estimasi ketika asumsi distribusi terpenuhi dan interpretasi langsung dalam bentuk *time ratio*. Namun, kelemahannya adalah jika data tidak sesuai dengan distribusi *Weibull*, hasil estimasi dapat menjadi bias dan prediksi kurang akurat. Beberapa penelitian menunjukkan bahwa *CoxPH* umumnya memberikan hasil lebih baik (*AIC* lebih rendah dan *C-index* lebih tinggi) dibanding *Weibull* pada data empiris.

G. Implikasi Model dalam Analisis Kesehatan

Pemilihan model *survival* sangat penting dalam analisis data kesehatan karena berpengaruh langsung terhadap ketepatan interpretasi klinis dan pengambilan keputusan medis. Dalam konteks penelitian seperti prediksi ketahanan hidup pasien gagal jantung atau kanker, model *Cox Proportional Hazards (CoxPH)* terbukti lebih unggul karena tidak memerlukan asumsi distribusi waktu *survival* dan memberikan interpretasi yang jelas melalui *hazard ratio*.

Hasil penelitian Zakiah et al. (2024) menunjukkan bahwa *CoxPH* efektif mengidentifikasi faktor-faktor yang memengaruhi waktu *survival* pasien kanker paru di RSUDZA Aceh, dengan hasil yang lebih akurat dibandingkan model parametrik. Nilai *AIC* dan *C-index* yang lebih baik menandakan kemampuan prediksi risiko yang lebih tinggi.

Namun, keandalan *CoxPH* tetap bergantung pada terpenuhinya asumsi *Proportional Hazards (PH)*. Jika asumsi tersebut dilanggar, maka model *Weibull Accelerated Failure Time (AFT)* dapat digunakan sebagai alternatif, terutama ketika data mengikuti distribusi *Weibull* dan analisis difokuskan pada durasi hidup atau *time ratio*. Menurut Soraya et al. (2018), model *Weibull AFT* memiliki keunggulan dalam menggambarkan pola waktu kejadian penyakit seperti demam berdarah, karena mampu mengekspresikan efek kovariat terhadap lamanya waktu bertahan pasien. Secara umum, model *CoxPH* direkomendasikan untuk analisis risiko relatif antar pasien, sedangkan *Weibull AFT* lebih sesuai untuk memperkirakan waktu bertahan hidup secara absolut, terutama pada penelitian dengan pola distribusi waktu *survival* yang teratur.

5. CONCLUSION

Penelitian ini bertujuan untuk menganalisis faktor-faktor yang memengaruhi ketahanan hidup pasien gagal jantung serta menilai kinerja model *Cox Proportional Hazards (CoxPH)* dan *Weibull Accelerated Failure Time (AFT)*. Hasil analisis menunjukkan bahwa variabel usia, anemia, hipertensi, kadar kreatinin serum, dan fraksi ejeksi memiliki pengaruh signifikan terhadap risiko kematian. Usia, anemia, hipertensi, dan kadar kreatinin yang tinggi meningkatkan risiko kematian, sedangkan fraksi ejeksi yang tinggi memberikan efek protektif terhadap mortalitas pasien gagal jantung.

Dari sisi kinerja model, *CoxPH* terbukti memberikan hasil yang lebih baik dengan nilai *AIC* lebih rendah (958,46) dan *C-index* lebih tinggi (0,741) dibanding *Weibull AFT* (*AIC* = 1282,24; *C-index* = 0,259). Hasil ini menunjukkan bahwa *CoxPH* lebih akurat dalam memeringkat risiko dan dapat diandalkan untuk interpretasi klinis. Namun, hasil uji asumsi menunjukkan bahwa fraksi ejeksi melanggar asumsi *Proportional Hazards (PH)*, sementara variabel lainnya memenuhi asumsi tersebut. Oleh karena itu, pada penelitian lanjutan disarankan penggunaan pendekatan *time-varying covariates* atau stratifikasi untuk menjaga validitas model.

Secara praktis, hasil penelitian ini menegaskan pentingnya stratifikasi risiko klinis berdasarkan usia lanjut, anemia, hipertensi, dan fungsi ginjal, dengan pemantauan *ejection fraction* sebagai indikator protektif terhadap mortalitas. Model *CoxPH* direkomendasikan sebagai alat utama untuk memperkirakan risiko relatif kematian, sedangkan model *Weibull AFT* dapat digunakan sebagai pelengkap dalam memperkirakan durasi bertahan hidup absolut. Penelitian selanjutnya diharapkan dapat memperluas ukuran sampel, melakukan validasi eksternal, serta kalibrasi model guna meningkatkan keandalan hasil dan penerapannya dalam konteks klinis yang lebih luas.

REFERENCES

- Alya, R., Mukhti, T. O., Wahyuni, S., Barokah, B. M., & Apriyerni, A. (2025). Survival analysis of heart failure patients using the Cox proportional hazard model and Weibull regression. *UNP Journal of Statistics and Data Science*, 3(2), 147-156. <https://doi.org/10.24036/ujsds/vol3-iss2/351>

- Ashine, T., Muleta, G., & Tadesse, K. (2021). Assessing survival time of heart failure patients using a Bayesian approach. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00537-4>
- Cavalcante, T., Ospina, R., Leiva, V., Cabezas, X., & Martin-Barreiro, C. (2023). Weibull regression and machine learning survival models: Methodology, comparison, and application to biomedical data related to cardiac surgery. *Biology*, 12(3). <https://doi.org/10.3390/biology12030442>
- Couissi, A., Haboub, M., Hamady, S., Ettachfini, T., & Habbal, R. (2024). Predictors of mortality in heart failure patients with reduced or mildly reduced ejection fraction: The CASABLANCA HF study. *Egyptian Heart Journal*, 76(1). <https://doi.org/10.1186/s43044-024-00436-y>
- Damayanti, S., Wuryandari, T., & Sudarno, S. (2024). Perbandingan analisis survival menggunakan regresi Cox proportional hazard dan regresi Weibull pada pasien COVID-19 di RSUD Taman Husada Bontang. *Jurnal Gaussian*, 12(3), 453–464. <https://doi.org/10.14710/j.gauss.12.3.453-464>
- Georgousopoulou, E. N., Pitsavos, C., Yannakoulia, C. M., & Panagiotakos, D. B. (2015). Comparisons between survival models in predicting cardiovascular disease events: Application in the ATTICA study (2002–2012). *Journal of Statistics Applications & Probability*, 4(2), 203. <https://doi.org/10.12785/jsap/040202>
- Giolo, S. R., Krieger, J. E., Mansur, A. J., & Pereira, A. C. (2012). Survival analysis of patients with heart failure: Implications of time-varying regression effects in modeling mortality. *PLoS ONE*, 7(6). <https://doi.org/10.1371/journal.pone.0037392>
- Habibi, D., Raffei, M., Chehrei, A., Shayan, Z., & Tafaqodi, S. (2018). Comparison of survival models for analyzing prognostic factors in gastric cancer patients. *Asian Pacific Journal of Cancer Prevention*, 19(3), 749–753. <https://doi.org/10.22034/APJCP.2018.19.3.749>
- Hamid, A. L. P., Subanti, S., & Susanti, Y. (2022). Analisis faktor yang berpengaruh terhadap waktu survival pasien penyakit ginjal kronis menggunakan uji asumsi proportional hazard. *Indonesian Journal of Applied Statistics*, 5(1), 12. <https://doi.org/10.13057/ijas.v5i1.48121>
- Hasan, I. K., Pakaya, W. A., Achmad, N., & Isa, D. R. (2021). Analisis survival menggunakan regresi Weibull pada laju kesembuhan pasien tuberkulosis paru di RSUD Aloe Saboe Kota Gorontalo. *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*, 9(1), 40–51. <https://doi.org/10.34312/euler.v9i1.10758>
- Kaindal, S., & Venkataramana, B. (2025). A comparative analysis of parametric survival models and machine learning methods in breast cancer prognosis. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-15696-0>
- Lee, S., Kim, H., Lee, H., Hahn, J., & Chang, M. J. (2025). Time-to-event modeling for survival prediction of osimertinib as the first- and second-line therapy. *Journal of Clinical Medicine*, 14(12). <https://doi.org/10.3390/jcm14124077>
- Li, X., Marcus, D., Russell, J., Aboagye, E. O., Ellis, L. B., Sheeka, A., Park, W. H. E., Bharwani, N., Ghaem-Maghani, S., & Rockall, A. G. (2024). Weibull parametric model for survival analysis in women with endometrial cancer using clinical and T2-weighted MRI radiomic features. *BMC Medical Research Methodology*, 24(1). <https://doi.org/10.1186/s12874-024-02234-1>
- Lukitasari, D., Setiawan, A., & Sasangko, L. R. (2015). Bayesian Survival Analysis Untuk Mengestimasi Parameter Model Weibull-Regression Pada Kasus Ketahanan Hidup Pasien Penderita Jantung Koroner. *d'Cartesian*, 4(1), 26–33. <https://doi.org/10.35799/dc.4.1.2015.7531>
- Montaseri, M., Rezaei, M., Khayati, A., Mostafaei, S., & Taheri, M. (2025). Survival parametric modeling for patients with heart failure based on kernel learning. *BMC Medical Research Methodology*, 25(1). <https://doi.org/10.1186/s12874-024-02455-4>
- Moreno-Sánchez, P. A. (2023). Improvement of a prediction model for heart failure survival through explainable artificial intelligence. *Frontiers in Cardiovascular Medicine*, 10. <https://doi.org/10.3389/fcvm.2023.1219586>
- Mumbulu, E. T., Nkodila, A. N., Saint-Joy, V., Moussinga, N., Makulo, J. R. R., & Buila, N. B. (2024). Survival and predictors of mortality in patients with heart failure in the cardiology department of the Center Hospitalier Basse Terre in Guadeloupe: Historical cohort study. *BMC Cardiovascular Disorders*, 24(1). <https://doi.org/10.1186/s12872-024-04268-1>
- Plana, D., Fell, G., Alexander, B. M., Palmer, A. C., & Sorger, P. K. (2022). Cancer patient survival can be parametrized to improve trial precision and reveal time-dependent therapeutic effects. *Nature Communications*, 13(1). <https://doi.org/10.1038/s41467-022-28410-9>
- Putri, E. D., Mukhti, T. O., Annisa, R., Putri, A., & Nasywa, S. (2025). Mortality trends in heart failure patients: A study using Cox regression models. *UNP Journal of Statistics and Data Science*, 3(2), 180–188. <https://doi.org/10.24036/ujsds/vol3-iss2/359>
- Sarumpaet, A. N., Wuryandari, T., & Sudarno, S. (2024). Penerapan model Weibull proportional hazard dan regresi Cox proportional hazard pada kondisi financial distress. *Jurnal Gaussian*, 13(2), 450–461. <https://doi.org/10.14710/j.gauss.13.2.450-461>
- Soraya, N., Nasution, Y. N., & Wahyuningsih, S. (2018). Model Cox proportional hazard pada kejadian bersama (ties) dengan metode Breslow (studi kasus: Pasien rawat inap demam berdarah dengue di Rumah Sakit Dirgahayu Samarinda periode Juli 2016 s.d Juni 2017). *Ekspansional*, 9(1), 95–104.
- Voeltz, D., Hoyer, A., Forkel, A., Schwandt, A., & Kuß, O. (2024). A parametric additive hazard model for time-to-event analysis. *BMC Medical Research Methodology*, 24(1). <https://doi.org/10.1186/s12874-024-02180-y>
- Yanti, H., & Purnamasari, I. (2022). *Prosiding Seminar Nasional Matematika, Statistika, dan Aplikasinya* (Terbitan II).
- Zakiah, S., Ramadhani, E., & Safitri, R. (2024). Cox proportional hazard regression model in analysis of factors affecting survival time (case study: Lung cancer patients at RSUDZA Aceh). *Transcendent Journal of Mathematics and Application*, 3(1). <https://doi.org/10.24815/tjoma.v3i1.38761>