

Original Article

Evaluation of Signal Processing and Deep Learning Methods for Inter-Beat Interval Extraction from Ballistocardiography Signals

Roya Tabashiri Isfahani¹, Ali Loghmani¹*, Amir Akhavan² and Amirtaha Taeibi³

1. Department of Mechanical Engineering, Isfahan University of Technology, Isfahan 84156-83111, Iran.

2. Department of Electrical and Computer Engineering, Isfahan University of Technology, Isfahan 84156-83111, Iran.

3. Department of Bioengineering, Lehigh University, Bethlehem, PA 18015, USA

Abstract: Cardiovascular diseases remain the leading cause of mortality worldwide, highlighting the critical need for continuous and non-invasive monitoring of cardiac function to enable early detection and effective management. Ballistocardiography (BCG), which captures the mechanical forces associated with cardiac activity, holds great promise for unobtrusive heart monitoring in daily-life settings without requiring direct electrode contact. However, the inherent complexity and high susceptibility to noise in BCG signals make the accurate extraction of key cardiac parameters—particularly inter-beat intervals (IBIs)—a challenging task. This study presents a comprehensive evaluation of five distinct signal processing and deep learning approaches for IBI estimation from BCG signals, validated against synchronized electrocardiogram (ECG) recordings. In contrast to the previous works, we employ a publicly available dataset distinct from those commonly used, enabling a broader assessment of method generalizability—particularly for the CLIE algorithm. The evaluated methods include: Continuous Local Interval Estimator (CLIE), CLIE with adaptive windowing, Multilayer Perceptron (MLP), Convolutional Neural Network (CNN), and Bidirectional Long Short-Term Memory (BiLSTM) network. For the deep learning methods (MLP and CNN), we propose novel network architectures specifically tailored to the characteristics of BCG signals, leading to improved performance compared to conventional designs. Furthermore, our BiLSTM-based method not only incorporates testing on a dataset different from that of previous reference studies, but also focuses on the accurate prediction of R-peak locations in the BCG signal, from which IBIs are subsequently derived. Evaluation based on Mean Absolute Error (MAE), 95th percentile error, and correlation coefficient shows that the CLIE method achieved the best overall IBI estimation accuracy, with an MAE of 28.7 milliseconds and the highest correlation coefficient (0.77). The BiLSTM method, while having a slightly higher MAE (40.1 milliseconds), demonstrated superior robustness to outliers by achieving the lowest 95th percentile error (9.5%). The MLP and CNN methods showed moderate performance, and the adaptive windowing variant of CLIE performed the worst. These findings demonstrate that accurate IBI extraction from BCG signals is feasible, and that both the CLIE and BiLSTM approaches are promising candidates for implementation in intelligent, home-based cardiac monitoring systems—offering, respectively, high accuracy and strong resilience to large errors.

Keywords: Ballistocardiography, Inter-Beat Intervals, Electrocardiogram, Neural Network, Signal Processing, Cardiovascular Health.

Received: Apr. 17, 2025; Revised: Aug. 31, 2025; Accepted: Sep. 09, 2025; Published Online: Dec. 15, 2025.

* Corresponding Author: a.loghmani@iut.ac.ir

How to Cite: Tabashiri Isfahani Roya, Loghmani Ali, Akhavan Amir, Evaluation of signal processing and deep learning methods for inter-beat interval extraction from ballistocardiography signals, Journal of Computational Methods in Engineering; 2025, 44(2), 49-61; doi.org/[10.47176/jcme.44.2.1056](https://doi.org/10.47176/jcme.44.2.1056).



Copyright © 2025 Isfahan University of Technology, Published by Isfahan University of Technology press. This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license (<https://creativecommons.org/licenses/by-nc/4.0/>). Non-commercial uses of the work are permitted, provided the original work is properly cited.



مقاله پژوهشی

ارزیابی روش‌های پردازش سیگنال و یادگیری عمیق برای استخراج

فواصل ضربان به ضربان از سیگنال بالیستوکاردیوگرافی

رویا تابشیری اصفهانی^۱، علی لقمانی^۱، امیر اخوان^{۲*} و امیرطه تائبی^۳

۱. دانشکده مهندسی مکانیک، دانشگاه صنعتی اصفهان، اصفهان، ایران

۲. دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان، اصفهان، ایران

۳. دانشکده مهندسی پزشکی، دانشگاه لیهای، ایالت پنسیلوانیا، آمریکا

چکیده- بیماری‌های قلبی-عروقی یکی از اصلی‌ترین عامل مرگ‌ومیر در جهان هستند و پایش مداوم و غیرتهاجمی شاخص‌های قلبی برای تشخیص زودهنگام و مدیریت این بیماری‌ها حیاتی است. سیگنال بالیستوکاردیوگرافی (BCG)، که بازتابی از نیروهای مکانیکی ناشی از فعالیت قلبی است، پتانسیل بالایی برای پایش سلامت قلب در محیط‌های روزمره و بدون نیاز به اتصال الکترود به بدن را فراهم می‌کند. با این حال، ماهیت پیچیده و حساس به نویز این سیگنال، استخراج دقیق پارامترهای کلیدی مانند فواصل ضربان به ضربان (IBI) را به یک چالش تبدیل کرده است. هدف اصلی این پژوهش، ارزیابی جامع پنج رویکرد متفاوت پردازش سیگنال و یادگیری عمیق برای استخراج دقیق IBI از سیگنال BCG و اعتبارسنجی آن‌ها با سیگنال مرجع الکتروکاردیوگرام (ECG) است. بدین منظور، از یک مجموعه داده عمومی شامل سیگنال‌های همزمان BCG و ECG از ۴۰ شرکت‌کننده استفاده شد. در این مطالعه روش‌های تخمین‌گر فاصله‌ای محلی پیوسته (CLIE)، روش CLIE با پنجره تطبیقی، شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی کانولوشنال (CNN) و شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه (BiLSTM) ارزیابی شده است. نتایج ارزیابی با استفاده از معیارهای میانگین خطای مطلق (MAE)، صدک ۹۵ خطا و ضریب همبستگی نشان داد که روش CLIE با MAE برابر با ۲۸/۷ میلی‌ثانیه و بالاترین ضریب همبستگی (۰/۷۷) بهترین عملکرد کلی را در دقت تخمین IBI داشته است. از سوی دیگر، روش BiLSTM با وجود خطای میانگین کمی بالاتر (۴۰/۱ میلی‌ثانیه)، با ثبت کمترین مقدار برای صدک ۹۵ خطا (۹/۵٪)، پایداری و قابلیت اطمینان بالایی در کنترل خطاهای بزرگ از خود نشان داد. روش‌های MLP و CNN عملکردی متوسط و روش پنجره تطبیقی ضعیف‌ترین عملکرد را داشتند. یافته‌های این تحقیق نشان می‌دهد که استخراج دقیق IBI از سیگنال BCG امری امکان‌پذیر است و روش‌های CLIE و BiLSTM به ترتیب به دلیل دقت بالا و پایداری مناسب، گزینه‌های امیدوارکننده‌ای برای توسعه سیستم‌های پایش سلامت هوشمند و خانگی هستند.

واژه‌های کلیدی: روش اجزای محدود، ریزشدگی محلی شبکه، گره‌های معلق، المان انتقالی، توابع شکل جایگزین.

دریافت مقاله: ۱۴۰۴/۰۴/۱۷، بازنگری: ۱۴۰۴/۰۶/۰۹، پذیرش: ۱۴۰۴/۰۶/۱۸، اولین انتشار: ۱۴۰۴/۰۹/۲۴

* نویسنده مسئول، a.loghmani@iut.ac.ir

حق انتشار این مستند، متعلق به دانشگاه صنعتی اصفهان است. © ۱۴۰۳

این مقاله تحت گواهی زیر منتشر شده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز



است:

فهرست علائم

p_i	نقطه لنگر پنجره شماره i	S_{MAP}	جفت‌های با دامنه حداکثر
S_{AMDF}	میانگین قدر مطلق اختلاف دامنه اصلاح شده	$trf(i)$	ماتریس خروجی STFT برای پنجره شماره i
S_{corr}	خودهمبستگی اصلاح شده	w_i	پنجره شماره i

۱. مقدمه


با افزایش شیوع بیماری‌های قلبی-عروقی در سراسر جهان و تبدیل شدن آن به یکی از اصلی‌ترین دلایل مرگومیر، نیاز به فناوری‌های نوین برای پایش مداوم و غیرتهاجمی سلامت قلب بیش از پیش احساس می‌شود. الکتروکاردیوگرام^۱ (ECG) به عنوان استاندارد طلایی برای ثبت فعالیت الکتریکی قلب شناخته می‌شود، اما محدودیت‌های ذاتی آن، از جمله نیاز به اتصال الکتروود به پوست و حضور متخصص، استفاده از آن را برای پایش طولانی‌مدت در محیط‌های خارج از بیمارستان، مانند خانه یا محل کار، دشوار می‌سازد [۱]. این محدودیت‌ها مانع از نظارت مستمر بر وضعیت بیمارانی می‌شود که نیاز به پایش دائمی دارند، به‌ویژه در شرایطی مانند همه‌گیری‌های جهانی که مراجعه به مراکز درمانی با ریسک همراه است. در این میان، بالیستوکاردیوگرافی^۲ (BCG) به عنوان یک روش جایگزین و امیدوارکننده مطرح شده است. این سیگنال که برای اولین بار در سال ۱۸۷۷ توسط گوردون کشف شد، حاصل بازتاب نیروهای مکانیکی بدن در پاسخ به پمپاژ خون توسط قلب و حرکت آن در شریان‌های بزرگ است. برخلاف ECG، سیگنال BCG می‌تواند به‌صورت غیرتماسی و از طریق حسگرهای تعبیه‌شده در تخت، صندلی یا حتی ترازوهای هوشمند ثبت شود. این ویژگی، امکان پایش پیوسته و بدون ایجاد مزاحمت برای فرد را در طول فعالیت‌های روزمره و به‌ویژه هنگام خواب فراهم می‌آورد [۲].

یکی از مهم‌ترین پارامترهایی که می‌توان از سیگنال‌های قلبی استخراج کرد، تغییرپذیری ضربان قلب^۳ (HRV) است که از طریق محاسبه فواصل زمانی بین ضربان‌های متوالی قلب^۴ (IBI) به دست می‌آید. HRV شاخصی کلیدی برای ارزیابی عملکرد سیستم عصبی خودکار و سلامت کلی سیستم قلبی-عروقی است.

کاهش HRV با افزایش خطر ابتلا به بیماری‌های قلبی، استرس مزمن و کاهش انعطاف‌پذیری فیزیولوژیکی بدن در ارتباط است. بنابراین، استخراج دقیق IBI و HRV از سیگنال BCG می‌تواند در پزشکی پیشگیرانه و مدیریت بیماری‌های مزمن مفید باشد [۳]. با این حال، استخراج اطلاعات دقیق از سیگنال BCG با چالش‌های جدی همراه است. این سیگنال به شدت به نویزهای ناشی از حرکات بدن (اغتشاشات ناشی از حرکت ماهیچه‌ها) و تنفس حساس است. علاوه بر این، شکل موج سیگنال BCG می‌تواند تحت تأثیر عواملی مانند نوع حسگر، محل قرارگیری آن و وضعیت فیزیکی فرد (خوابیده، نشسته) به شدت تغییر کند. این تنوع و حساسیت به نویز، استفاده از الگوریتم‌های پردازش سیگنال سنتی را که متکی بر شناسایی قله‌های مشخص هستند، با مشکل مواجه می‌سازد [۴].

در دهه‌های اخیر، با پیشرفت در فناوری حسگرها و ظهور روش‌های پیشرفته پردازش سیگنال و یادگیری عمیق، تحقیقات در زمینه BCG جان تازه‌ای گرفته است [۵-۷]. مطالعات متعددی پتانسیل این سیگنال را برای تخمین ضربان قلب، فشار خون و قدرت انقباضی قلب نشان داده‌اند. با این وجود، همچنان نیاز به ارزیابی جامع و مقایسه‌ای روش‌های مختلف برای استخراج دقیق IBI از BCG احساس می‌شود [۴، ۸ و ۹].

هدف اصلی این پژوهش، ارزیابی و مقایسه عملکرد پنج رویکرد متمایز برای استخراج فواصل ضربان به ضربان از سیگنال BCG است. این رویکردها شامل دو روش کلاسیک پردازش سیگنال CLIE و CLIE با پنجره تطبیقی و معماری‌های مهم یادگیری عمیق شامل MLP، CNN و BiLSTM هستند. در این مطالعه، برخلاف پژوهش‌های پیشین، از یک مجموعه داده عمومی متفاوت شامل سیگنال‌های همزمان BCG و ECG از ۴۰



شکل ۱. سیستم جمع‌آوری داده‌ها در پژوهش

مرجع طلایی، امکان ارزیابی دقیق الگوریتم‌های توسعه داده شده برای BCG را فراهم می‌آورد [۱۰]. مطابق با شکل ۱ سیگنال BCG با استفاده از چهار حسگر فیلم الکترومکانیکی^۶ در زیر تشک و چهار لودسل^۷ در زیر پایه‌های تخت ثبت شده است. سیگنال ECG نیز با استفاده از یک دستگاه سه لید^۸ جمع‌آوری گردیده است. نرخ نمونه‌برداری تمام سیگنال‌ها ۱۰۰۰ هرتز بوده است. برای پیش‌پردازش، یک فیلتر میان‌گذر بر روی سیگنال‌های BCG (۱-۱۰ هرتز) و ECG (۱۵-۵ هرتز) اعمال شد تا نویزهای فرکانس پایین و بالا حذف شوند [۱۰].

۳. استخراج IBI مرجع از سیگنال ECG

به منظور دستیابی به مقادیر واقعی فواصل ضربان به ضربان، از الگوریتم پن-تامپکینز^۹ برای تشخیص قله‌های R در سیگنال ECG استفاده شد. این الگوریتم یک روش استاندارد و قوی است که شامل مراحل فیلتر میان‌گذر، مشتق‌گیری، به توان دو رساندن، انتگرال‌گیری با پنجره متحرک و در نهایت تشخیص قله با استفاده از آستانه‌های تطبیقی است. فیلترگذاری با اعمال یک فیلتر میان‌گذر با فرکانس‌های قطع ۵ و ۱۵ هرتز انجام می‌شود تا نویزهای فرکانس پایین و فرکانس بالا حذف شوند. سپس با محاسبه مشتق مرتبه اول سیگنال، تغییرات سریع دامنه که عمدتاً مربوط به مجموعه QRS

شرکت‌کننده استفاده شده که امکان سنجش تعمیم‌پذیری روش‌ها، به‌ویژه CLIE، در شرایط متنوع‌تری را فراهم می‌کند. در روش‌های مبتنی بر یادگیری عمیق MLP و CNN، معماری‌های شبکه به‌صورت اختصاصی طراحی و بهینه‌سازی شده‌اند که نسبت به ساختارهای رایج در مطالعات مشابه، عملکرد بهتری را در تخمین IBI نشان داده‌اند. در مورد BiLSTM، علاوه بر ارزیابی آن روی مجموعه داده‌ای مستقل از مقاله مرجع، تمرکز اصلی بر پیش‌بینی دقیق مکان موج R از سیگنال BCG قرار گرفته است تا فواصل IBI به‌طور مستقیم از اختلاف زمانی بین پیک‌های R حاصل شوند. نتایج این تحقیق می‌تواند راه را برای توسعه دستگاه‌های پایش سلامت هوشمند، خانگی و قابل اعتماد هموار سازد.

۲. مجموعه داده

در این پژوهش از مجموعه داده عمومی و معتبری که توسط کارلسون و همکاران در دانشگاه ایالتی کانزاس تهیه شده است، استفاده گردید. این مجموعه داده شامل سیگنال‌های همزمان ECG، BCG، فتوپلتیسموگرافی^۵ (PPG) و فشار خون شریانی از ۴۰ شرکت‌کننده (۱۷ مرد، ۲۳ زن) با دامنه سنی ۱۸ تا ۶۵ سال و شاخص توده بدنی متنوع است. وجود سیگنال ECG به عنوان

$S_{corr}[N]$ تابع همبستگی محاسبه شده برای تعداد نمونه N است. W نیز مقادیر پنجره را نشان می‌دهد. لازم به ذکر است که پنجره‌گذاری در سیگنال با منطبق کردن یک مختصات محلی روی بخش پنجره‌گذاری شده از سیگنال همراه است به طوری که $w[0]$ نشانگر مرکز پنجره باشد. با توجه به این نکته و رابطه می‌توان فهمید که در این تابع، برای هر $N \in \{N_{min}, N_{max}\}$ همبستگی بین N نمونه سمت راست و N نمونه سمت چپ مرکز پنجره محاسبه می‌شود.

تخمین گر ۲: تابع میانگین قدر مطلق اختلاف دامنه اصلاح شده^{۱۳} که معکوس میانگین اختلاف بین نمونه‌های متناظر را محاسبه می‌کند و با رابطه ۲ محاسبه می‌شود.

$$S_{AMDF}[N] = \frac{1}{N} \sum_{v=0}^N (|w[v] - w[v - N]|)^{-1} \quad (2)$$

$S_{AMDF}[N]$ تابع میانگین قدر مطلق اختلاف دامنه اصلاح شده است و مجدداً w مقادیر پنجره را نشان می‌دهد.

تخمین گر ۳: جفت‌های با دامنه حداکثر^{۱۴} که حداکثر مجموع دامنه جفت نمونه‌هایی که به فاصله N از هم قرار دارند را پیدا می‌کند و طبق رابطه ۳ محاسبه می‌شود و به عنوان یک آشکارساز قله‌ی غیرمستقیم محسوب می‌شود.

$$S_{MAP} = \max_{v \in [0, \dots, N]} (w[v] + w[v + N]) \quad (3)$$

ج- ترکیب احتمالی: خروجی هر سه تخمین گر به یک تابع چگالی احتمال^{۱۵} (PDF) تبدیل شده و با ضرب آن‌ها در یکدیگر، یک PDF ترکیبی حاصل می‌شود. مقداری از N که این PDF ترکیبی را حداکثر کند، به عنوان IBI تخمینی برای آن پنجره در نظر گرفته می‌شود.

د- شناسایی نقاط لنگر^{۱۶} و میانه‌گیری: به دلیل همپوشانی بالای پنجره‌های تحلیلی، هر فاصله‌ی ضربان به ضربان در چندین پنجره متوالی تخمین زده می‌شود. برای تجمع این تخمین‌ها، نقاط لنگر در سیگنال شناسایی شده و میانه تخمین‌های مربوط به یک نقطه لنگر به عنوان مقدار نهایی IBI در نظر گرفته می‌شود. نقطه لنگر طبق یک قرارداد از بین قله‌های سمت راست مرکز پنجره با شرطی مطابق رابطه ۴ مشخص می‌شود.

$$P_i = n_i + \arg \max_{m \in M_i} (w_i[m] + w_i[m - N_i]) \quad (4)$$

هستند برجسته می‌شوند. در ادامه، سیگنال مشتق گرفته شده به توان دو رسانده می‌شود تا همه مقادیر مثبت شده و قله‌های QRS تقویت شوند پس از آن نیز یک انتگرال‌گیری با پنجره متحرک روی سیگنال انجام می‌شود تا اطلاعات مربوط به عرض و دامنه مجموعه QRS ترکیب شود. در نهایت، با استفاده از آستانه‌گذاری تطبیقی و به کارگیری دانش فیزیولوژیکی مانند حداقل فاصله بین دو ضربان، محل دقیق قله‌های R شناسایی می‌شود. آستانه‌ها به صورت پویا و با توجه به مشخصات اخیر سیگنال به روزرسانی می‌شوند تا تطبیق پذیری الگوریتم افزایش یابد. پس از شناسایی دقیق موقعیت زمانی هر قله R، فاصله زمانی بین دو قله R متوالی به عنوان IBI مرجع محاسبه گردید [۱۱].

۴. روش‌های استخراج IBI از سیگنال BCG

پنج رویکرد متفاوت برای استخراج IBI از سیگنال BCG پیاده‌سازی و ارزیابی شدند که در ادامه تشریح می‌شوند.

۱.۴. روش تخمین گر فاصله‌ای محلی پیوسته

روش تخمین گر فاصله‌ای محلی پیوسته^{۱۷} (CLIE) که توسط بروسر و همکاران [۱۲] ارائه شده، به جای تلاش برای یافتن قله‌های مشخص در سیگنال، مستقیماً فاصله بین ضربان‌ها را تخمین می‌زند. این ویژگی آن را در برابر تغییرات مورفولوژی^{۱۱} سیگنال BCG مقاوم می‌سازد. مراحل این الگوریتم به شرح زیر است [۱۲]:

الف- پنجره‌گذاری: سیگنال BCG با یک پنجره لغزنده ۳ ثانیه‌ای و با همپوشانی بالا (۲/۹ ثانیه) پیمایش می‌شود.

ب- اعمال تخمین گر‌ها: در هر پنجره، سه تخمین گر برای یافتن محتمل ترین فاصله ضربان به ضربان، اعمال می‌شوند: تخمین گر ۱: تابع خودهمبستگی اصلاح شده^{۱۲} که همبستگی بین نیمه راست و چپ پنجره را با رابطه ۱ محاسبه می‌کند.

$$S_{corr}[N] = \frac{1}{N} \sum_{v=0}^N w[v]w[v - N] \quad (1)$$

شده در روش CLIE بود. برای هر پنجره سه ثانیه‌ای از سیگنال BCG، سه PDF (هر کدام به طول ۵۵) به یکدیگر متصل شده و یک بردار ویژگی ۱۶۵ بعدی را به عنوان ورودی شبکه تشکیل دادند. خروجی مطلوب، فواصل استخراج شده از سیگنال ECG متناظر است. معماری شبکه شامل چندین لایه کاملاً متصل^{۱۹} با توابع فعال‌سازی ReLU بود و لایه خروجی برای پیش‌بینی مقادیر IBI طراحی شد [۱۴]. جزئیات معماری شبکه در جدول ۱ آمده است.

۴.۴. شبکه عصبی کانولوشنال

شبکه‌های عصبی کانولوشنی^{۲۰} (CNN) در استخراج ویژگی‌های مکانی از داده‌ها توانمند هستند. در این رویکرد، به جای اتصال PDFها به صورت یک بردار، آن‌ها به عنوان کانال‌های مختلف یک تصویر در نظر گرفته شدند. ورودی شبکه یک ماتریس با ابعاد ۵۵×۳ بود که هر ستون آن متناظر با یکی از PDFهای روش CLIE بود. معماری شبکه شامل لایه‌های کانولوشنال برای استخراج ویژگی، لایه‌های Batch Normalization برای پایداری آموزش، لایه‌های Max Pooling برای کاهش ابعاد و در نهایت لایه‌های کاملاً متصل برای رگرسیون و پیش‌بینی IBI بود [۱۵]. جزئیات معماری شبکه CNN در جدول ۱ آمده است.

۴.۵. شبکه عصبی با حافظه طولانی و کوتاه‌مدت دوطرفه

برخلاف دو روش قبلی که از ویژگی‌های استخراج شده (PDFs) استفاده می‌کردند، در این رویکرد، شبکه مستقیماً از سیگنال خام برای یادگیری استفاده کرد. با الهام از مطالعه مورکوما و همکاران، یک شبکه عصبی با حافظه طولانی و کوتاه مدت دوطرفه^{۲۱} (BiLSTM) برای تولید سیگنال ECG از روی سیگنال BCG آموزش داده شد. شبکه‌های BiLSTM قادر به یادگیری وابستگی‌های زمانی بلندمدت در داده‌های سری زمانی، هم در جهت گذشته به آینده و هم آینده به گذشته، هستند. ورودی شبکه، بخش‌های ۴ ثانیه‌ای از سیگنال BCG و خروجی مطلوب، سیگنال ECG متناظر است. پس از آموزش، شبکه قادر است

در رابطه ۴، P_i نقطه لنگر پنجره i ام و n_i مرکز همان پنجره است. M_i نیز مجموعه‌ی قله‌های سمت راست پنجره‌ی i است که از بین آن‌ها نقطه لنگر جدا می‌شود. در آخر برای جبران داده‌های پرت، میان N_i های تخمینی برای پنجره‌هایی که نقاط لنگر یکسانی دارند، میانه داده‌ها گرفته می‌شود.

۲.۴. رویکرد CLIE با پنجره تطبیقی

یک ضعف رویکرد CLIE، استفاده از پنجره با طول ثابت است که ممکن است بسته به ضربان قلب فرد، بهینه نباشد. در حالت استراحت ضربان قلب از ۴۰ تا ۱۴۰ ضربه در دقیقه تغییر می‌کند. در روش CLIE طول پنجره لغزنده در طول سیگنال همواره ثابت و برابر ۳ ثانیه است. این طول ۳ ثانیه‌ای، باعث می‌شود حتی در حالتی که ضربان قلب فرد نزدیک ۴۰ ضربان در دقیقه باشد، حتماً دو چرخه قلبی در پنجره آنالیزی موجود باشد. اما برای حالت‌های دیگری که ضربان فرد از ۴۰ ضربان در دقیقه دور شده و به ۱۴۰ ضربان در دقیقه نزدیک می‌شود، این طول پنجره ثابت باعث شود گاهی تا چهار سیکل قلبی در پنجره باشد. در این رویکرد اصلاح شده، طول پنجره به صورت پویا تنظیم می‌شود. این کار با استخراج یک سیگنال کمکی $S(t)$ از طریق تبدیل فوریه کوتاه‌مدت^{۱۷} سیگنال BCG انجام می‌گیرد. $S(t)$ با تجمیع انرژی در باند فرکانسی غالب موج J (معمولاً ۷-۴ هرتز) به دست می‌آید و قله‌های آن، مکان تقریبی ضربان‌ها را مشخص می‌کنند. فاصله بین این قله‌ها برای تعیین طول بهینه پنجره در هر لحظه استفاده می‌شود. برای محاسبه $S(t)$ از رابطه ۵ کمک گرفته می‌شود. پس از پیدا کردن محل تقریبی قله‌های J از سیگنال BCG که تناظر نسبتاً خوبی با قله‌های سیگنال $S(t)$ دارند، این بار طول پنجره‌ها به اندازه دو برابر فاصله‌ی قله‌های متوالی از سیگنال $S(t)$ انتخاب می‌شوند [۱۳].

$$S(t) = \sum_{trf(:,4:5)}^{trf(:,7)} trf(i) \quad (5)$$

۳.۴. شبکه عصبی پرسپترون چندلایه

برای بهره‌گیری از قابلیت یادگیری الگوهای غیرخطی، یک شبکه عصبی پرسپترون چندلایه^{۱۸} (MLP) طراحی شد. ورودی این شبکه، بردارهای حاصل از توابع چگالی احتمال (PDFs) تولید

جدول ۱. ساختار شبکه MLP

شماره لایه	نام لایه	نوع لایه	اندازه ورودی لایه	اندازه خروجی لایه	پارامترهای قابل یادگیری
۱	imageinput	ورودی تصویر	۱۶۵×۱۶۵	۱۶۵×۱۶۵	-
۲	fc_1	Fully Connected	۱۶۵×۱۶۵	۱×۲۵۶	وزن: ۲۵۶×۱۶۵ بایاس: ۲۵۶×۱
۳	relu_1	ReLU	۱×۲۵۶	۱×۲۵۶	-
۴	fc_2	Fully Connected	۱×۲۵۶	۱×۱۲۸	وزن: ۱۲۸×۲۵۶ بایاس: ۱۲۸×۱
۵	relu_2	ReLU	۱×۱۲۸	۱×۱۲۸	-
۶	fc_3	Fully Connected	۱×۱۲۸	۱×۶۴	وزن: ۶۴×۱۲۸ بایاس: ۶۴×۱
۷	relu_3	ReLU	۱×۶۴	۱×۶۴	-
۸	fc_4	Fully Connected	۱×۶۴	۱×۵	وزن: ۵×۶۴ بایاس: ۱×۵
۹	relu_4	ReLU	۱×۵	۱×۵	-
۱۰	regressionoutput	Regression Output	۱×۵	۱×۵	-

p_value : نشان دهنده معناداری ضریب همبستگی از نظر آماری است. یک p_value پایین در کنار یک ضریب همبستگی بالا بیانگر آن است که همبستگی مشاهده شده به احتمال زیاد تصادفی نیست. ابتدا خطاهای بین دو روش که یکی از آنها مرجع مقایسه است محاسبه شده، سپس توزیع نرمال خطاها با استفاده از آزمون لیلیفورس^{۲۵} بررسی می‌شود. در صورت عدم رد فرض نرمال بودن خطاها، آزمون t برای مقایسه دو بردار به کار رفته و مقدار p گزارش شده است. اگر نتیجه آزمون t معنادار بود، تفاوت بین دو روش معنی‌دار در نظر گرفته شده و در غیر این صورت تفاوت به صورت آماری، معنی‌دار شناخته نمی‌شود. در صورتی که فرض نرمال بودن خطاها رد شود، از آزمون ویلکاکسون^{۲۶} استفاده شده و مقدار p این آزمون گزارش شده است. مشابه آزمون t ، در این آزمون نیز وجود یا عدم وجود تفاوت معنی‌دار آماری تعیین می‌گردد. این رویکرد تضمین می‌کند که تحلیل آماری متناسب با توزیع داده‌ها انجام شده و نتیجه‌گیری دقیقی درباره تفاوت بین دو مجموعه داده حاصل شود.

سیگنال ECG پیش‌بینی‌شده را تولید کند. سپس الگوریتم پن‌تامپکینز بر روی این سیگنال پیش‌بینی‌شده اعمال می‌شد تا IBIها استخراج شوند [۱۶]. در جدول ۲ جزئیات این شبکه مشاهده می‌شود.

۵. معیارهای ارزیابی

- عملکرد هر پنج روش با استفاده از معیارهای آماری زیر و در مقایسه با IBIهای مرجع حاصل از ECG ارزیابی شد:
- میانگین خطای مطلق (MAE)^{۲۲}: میانگین قدر مطلق تفاوت بین مقادیر تخمینی و واقعی است.
 - صدک ۹۵ خطا^{۲۳}: مقداری که ۹۵٪ از خطاهای نسبی کمتر یا مساوی آن هستند. این معیار نشان‌دهنده پایداری روش در برابر خطاهای بزرگ است.
 - ضریب همبستگی^{۲۴}: قدرت و جهت رابطه خطی بین مقادیر تخمینی و واقعی را می‌سنجد.

جدول ۱. ساختار شبکه CNN


شماره لایه	نام لایه	نوع لایه	اندازه ورودی	اندازه خروجی	پارامترهای قابل یادگیری
۱	imageinput	Image Input	$55 \times 3 \times 1$	$55 \times 3 \times 1$	-
۲	conv_1	ConVolution (فیلتر $3 \times 1, 16$)	$55 \times 3 \times 1$	$55 \times 3 \times 16$	وزن: $3 \times 1 \times 1 \times 16$ بایاس: $1 \times 1 \times 1 \times 16$
۳	batchnorm_1	Batch Normalization	$55 \times 3 \times 16$	$55 \times 3 \times 16$	Offset $1 \times 1 \times 1 \times 16$ Scale $1 \times 1 \times 1 \times 16$
۴	relu_1	ReLU	$55 \times 3 \times 16$	$55 \times 3 \times 16$	-
۵	maxpool	Max Pooling (2×1 , stride 2×1)	$55 \times 3 \times 16$	$27 \times 3 \times 16$	-
۶	conv_2	ConVolution (فیلتر $3 \times 1, 32$)	$27 \times 3 \times 16$	$27 \times 3 \times 32$	وزن: $3 \times 1 \times 16 \times 32$ بایاس: $1 \times 1 \times 1 \times 32$
۷	batchnorm_2	Batch Normalization	$27 \times 3 \times 32$	$27 \times 3 \times 32$	Offset $1 \times 1 \times 1 \times 32$ Scale $1 \times 1 \times 1 \times 32$
۸	relu_2	ReLU	$27 \times 3 \times 32$	$27 \times 3 \times 32$	-
۹	fc_1	Fully Connected (۶۴ نورون)	2592×1	$1 \times 1 \times 64$	وزن: 64×2592 بایاس: 64×1
۱۰	relu_3	ReLU	$1 \times 1 \times 64$	$1 \times 1 \times 64$	-
۱۱	fc_2	Fully Connected (۵ نورون)	$1 \times 1 \times 64$	$1 \times 1 \times 5$	وزن: 5×64 بایاس: 5×1
۱۲	relu_4	ReLU	$1 \times 1 \times 5$	$1 \times 1 \times 5$	-
۱۳	regressionoutput	Regression Output	$1 \times 1 \times 5$	$1 \times 1 \times 5$	-

جدول ۲. ساختار شبکه BiLSTM

شماره لایه	نام لایه	نوع لایه	اندازه ورودی	اندازه خروجی	پارامترهای قابل یادگیری
۱	sequenceinput	Sequence Input (1D)	$(T \times 1)$ دنباله با ابعاد	دنباله با ابعاد $(T \times 1)$	-
۲	biLSTM	BiLSTM (۱۲۸ واحد)	$(T \times 1)$ دنباله با ابعاد	۲۵۶	وزن ورودی 1024×1 وزن بازگشتی 1024×1 بایاس 1024×1
۳	fc_1	Fully Connected (۶۴ نورون)	۲۵۶	۶۴	وزن 64×256 بایاس 64×1
۴	relu	ReLU	۶۴	۶۴	-
۵	fc_2	Fully Connected (۱ نورون)	۶۴	۱	وزن 1×64 بایاس 1×1
۶	regressionoutput	Regression Output	۱	۱	-

جدول ۳. مقایسه عملکرد کلی پنج روش برای استخراج IBI از سیگنال BCG

	ضریب همبستگی	صدک ۹۵ خطا (درصد)	میانگین خطای مطلق (ms)	p-value
CLIE	۰/۷۶۹۷	۱۲/۲۴۴۵	۲۸/۶۹۵۵	<۰/۰۰۱
پنجره تطبیقی	۰/۴۰۸۷	۴۵/۱۷۴۳	۱۵۷/۱۰۷۰	<۰/۰۰۱
MLP	۰/۷۲۰۸	۳۶/۶۶۲۱	۶۶/۰۹۴۸	<۰/۰۰۱
CNN	۰/۶۷۳۹	۳۳/۳۹۸۴	۷۵/۸۰۶۵	<۰/۰۰۱
BiLSTM	۰/۶۲	۹/۴۵۷۲	۴۰/۱۱۰۱	<۰/۰۰۱



شکل ۲. نمودار بلند آلتمن روش CLIE

۶.۱. نتایج کلی و مقایسه روش‌ها


جدول ۳ خلاصه‌ای از عملکرد کلی پنج روش را روی کل مجموعه داده نشان می‌دهد.

بر اساس نتایج جدول ۳، روش CLIE با ثبت کمترین میانگین خطای مطلق (۲۸/۷ میلی‌ثانیه) و بالاترین ضریب همبستگی (۰/۷۷)، دقیق‌ترین عملکرد را در تخمین IBI از خود نشان داد. این نتیجه بیانگر توانایی بالای این روش در دنبال کردن تغییرات ضربان قلب با دقت بالا است. از سوی دیگر، روش BiLSTM با اینکه ضریب همبستگی و MAE ضعیف‌تر از CLIE داشت، با ثبت کمترین مقدار برای

- نمودار بلند-آلتمن^{۲۷}: ابزاری گرافیکی برای ارزیابی توافق^{۲۸} بین دو روش اندازه‌گیری که بایاس^{۲۹} و حدود توافق^{۳۰} را نشان می‌دهد.

۶. نتایج و بحث

در این بخش، نتایج کمی و کیفی حاصل از پیاده‌سازی پنج روش مورد بررسی ارائه می‌شود. لازم به ذکر است که سیگنال ECG داوطلب شماره ۸ در مجموعه داده دارای نویز شدید و غیرقابل استفاده بود، بنابراین این داوطلب از تحلیل حذف گردید.



شکل ۳ نمودار بلند آلتمن شبکه BiLSTM

صدک ۹۵ خطا مطابقت دارد. شکل ۴ نیز مقایسه سری زمانی IBIهای تخمینی توسط روش CLIE با مقادیر واقعی را برای یک شرکت‌کننده نمونه نشان می‌دهد. همانطور که مشاهده می‌شود، تخمین‌های CLIE (خط آبی) به خوبی تغییرات IBI واقعی (خط قرمز) را دنبال می‌کنند.


۳.۶. بحث و بررسی

نتایج این پژوهش نشان‌دهنده تفاوت در عملکرد روش‌های مختلف برای استخراج پارامترهای قلبی از سیگنال BCG است. موفقیت روش CLIE را می‌توان به فلسفه اصلی آن نسبت داد. این روش به جای تمرکز بر یافتن ویژگی‌های مورفولوژیکی ناپایدار مانند قله J، مستقیماً به دنبال یافتن فواصل ضربان به ضربان در یک بازه زمانی کوتاه است. استفاده از سه تخمین‌گر مکمل (همبستگی، اختلاف دامنه و دامنه حداکثر) و ترکیب احتمالی آن‌ها، باعث افزایش مقاومت الگوریتم در برابر نویز و تغییرات شکل موج می‌شود. این رویکرد، آن را به گزینه‌ای بسیار دقیق و قوی برای تخمین IBI تبدیل کرده است. عملکرد برجسته BiLSTM در پایداری نیز قابل توجه است. این شبکه با یادگیری مستقیم نگاشت بین سیگنال BCG و ECG، قادر است الگوهای زمانی پیچیده و وابستگی‌های بلندمدت را مدل‌سازی کند. توانایی

صدک ۹۵ خطا (۹/۴۶٪)، عملکردی بهتری در کنترل خطاهای بزرگ و پایداری از خود نشان داد. این یعنی BiLSTM در ۹۵ درصد موارد، خطایی کمتر از ۱۰٪ دارد که قابلیت اطمینان آن را در شرایط واقعی افزایش می‌دهد. روش‌های مبتنی بر MLP و CNN عملکردی متوسط داشتند و اگرچه از روش پنجره تطبیقی بهتر بودند، اما از نظر دقت و پایداری در سطح پایین‌تری نسبت به CLIE و BiLSTM قرار گرفتند. روش پنجره تطبیقی با ثبت بالاترین خطا و کمترین همبستگی، ضعیف‌ترین عملکرد را داشت و نشان داد که در عمل کارایی مناسبی ندارد.

۲.۶. تحلیل گرافیکی نتایج

نمودارهای بلند-آلتمن توافق بین مقادیر تخمینی و واقعی را به تصویر می‌کشند. شکل ۳ نمودار بلند-آلتمن را برای دو روش برتر، یعنی CLIE و BiLSTM، نشان می‌دهد. در نمودار مربوط به CLIE، اکثر نقاط به خط میانگین (بایاس) نزدیک هستند که نشان‌دهنده خطای سیستماتیک پایین است. پراکندگی نقاط معقول است و دقت بالای روش را تأیید می‌کند. در نمودار BiLSTM، اگرچه ممکن است پراکندگی کلی کمی بیشتر باشد، اما تعداد نقاطی که خارج از محدوده توافق قرار می‌گیرند (خطاهای بزرگ) بسیار کم است که با مقدار پایین



شکل ۴ مقایسه IBI های واقعی (ECG) و تخمینی (BCG) برای داوطلب هفتم

برای الگوریتم CLIE، برای یادگیری توسط این معماری‌های عمیق بهینه نباشند. به عبارت دیگر، ممکن است اطلاعات مهمی از سیگنال اصلی در فرآیند استخراج PDF از دست رفته باشد. این موضوع نشان می‌دهد که در یادگیری عمیق، انتخاب ویژگی یا استفاده مستقیم از داده خام می‌تواند تأثیر زیادی بر نتیجه نهایی داشته باشد.

این یافته‌ها پیامدهای مهمی برای کاربردهای بالینی و خانگی دارند. برای کاربردهایی که حداکثر دقت در تخمین لحظه‌ای ضربان قلب اولویت دارد (مانند تحلیل HRV در حوزه فرکانس)، روش CLIE گزینه برتری است. اما برای سیستم‌های پایش طولانی‌مدت که قابلیت اطمینان و پایداری در برابر نویز و آرتیفک‌های حرکتی (مثلاً در طول خواب) اهمیت بیشتری دارد، روش BiLSTM به دلیل توانایی در جلوگیری از خطاهای فاحش، انتخاب مناسب‌تری به نظر می‌رسد.

پردازش دوطرفه (گذشته و آینده) به آن اجازه می‌دهد تا پیش‌بینی دقیق‌تری از شکل موج ECG، به‌ویژه در نواحی پیچیده مانند کمپلکس QRS، داشته باشد. این امر منجر به کاهش خطاهای بزرگ و پراکنده می‌شود، زیرا پیش‌بینی شبکه کمتر تحت تأثیر یک نویز لحظه‌ای قرار می‌گیرد و به زمینه کلی سیگنال متکی است.

در مقابل، عملکرد ضعیف روش پنجره تطبیقی به آسیب‌پذیری سیگنال کمکی $S(t)$ در برابر نویز بازمی‌گردد. در مواردی که سیگنال BCG دارای آرتیفک‌های حرکتی بود، سیگنال $S(t)$ قادر به تشخیص صحیح قله‌ها نبود و طول پنجره را به اشتباه تخمین می‌زد که این امر کل فرآیند الگوریتم CLIE را مختل می‌کرد.

عملکرد متوسط شبکه‌های MLP و CNN ممکن است به دلایل مختلفی باشد. این شبکه‌ها روی ویژگی‌های استخراج شده آموزش دیدند. ممکن است این ویژگی‌ها، با وجود مناسب بودن

۷. نتیجه‌گیری

نتایج نشان داد که روش CLIE با میانگین خطای مطلق $28/70$ میلی‌ثانیه و ضریب همبستگی $0/77$ ، دقیق‌ترین تخمین را ارائه داد. BiLSTM با صدک 95 خطای $9/47$ ٪، از نظر پایداری در شرایط مختلف بهترین عملکرد را داشت. در مقابل، روش پنجره تطبیقی با میانگین خطای $157/11$ میلی‌ثانیه و همبستگی $0/41$ ، ضعیف‌ترین نتایج را نشان داد. روش‌های MLP و CNN عملکرد متوسطی داشتند. در تمامی روش‌ها، مقادیر p بسیار کمتر از $0/001$ بودند که نشان‌دهنده معناداری بالای نتایج این روش‌ها نسبت به مرجع ECG است.

در مجموع، نتایج این مطالعه نشان می‌دهد که روش CLIE، نسبت به شبکه‌های عصبی عمیق عملکرد دقیق‌تری در تحلیل سیگنال BCG دارند. با این حال، مدل‌های یادگیری مانند BiLSTM با پایداری بالا در شرایط متغیر، گزینه‌ای مناسب برای کاربردهای مقاوم در برابر نویز به‌شمار می‌روند.

استخراج فواصل ضربان به ضربان از سیگنال BCG، با هدف تخمین HRV، گامی حیاتی در توسعه سامانه‌های پایش غیرتماسی و مداوم سلامت قلبی است. در این مطالعه با استفاده از مجموعه داده جمع‌آوری شده توسط محققان دانشگاه ایالتی کانزاس که شامل سیگنال‌های BCG و ECG هم‌زمان است، پنج روش شامل دو الگوریتم مبتنی بر استخراج ویژگی (CLIE و CLIE با پنجره تطبیقی) و سه مدل یادگیری عمیق (MLP، CNN و BiLSTM) برای استخراج IBI از BCG مورد ارزیابی قرار گرفتند. عملکرد هر روش با مقایسه با سیگنال مرجع ECG و بر اساس معیارهایی نظیر میانگین خطای مطلق، صدک 95 خطا، ضریب همبستگی و معناداری آماری (p-value) سنجیده شد.

واژه نامه

1. Electrocardiogram	2. Ballistocardiography	3. Heart rate variability
4. Inter beat interval	5. Photoplethysmography	6. Electromechanical film
7. Load cell	8. Lead	9. Pan-Tompkins
10. Continuous local interval estimation	11. Morphology	12. Modified autocorrelation
13. Average magnitude difference function	14. Maximum amplitude pairs	15. Probability density function
16. Anchor point	17. Short time Fourier transform	18. Multilayer perceptron
19. Fully connected layer	20. Convolutional	21. Bidirectional Long_Short Term Memory
22. Mean absolute error	23. 95th percentile error	24. Correlation coefficient
25. Correlation coefficient	26. Wilcoxon	27. Bland-Altman plot
28. Agreement	29. Bias	30. Limits of agreement

مراجع

- Inan O.T., Migeotte P.F., Park K.S., Etemadi M., Tavakolian K., Casanella R., Zanetti J., Tank J., Funtova I., Prisk G.K. Ballistocardiography and seismocardiography: A review of recent advances. *IEEE Journal of Biomedical and Health Informatics*. 2015;19(4):1414–1427. <https://doi.org/10.1109/JBHI.2014.2361732>
- Wang F., Zou Y., Tanaka M., Matsuda T., Chonan S. Unconstrained cardiorespiratory monitor for premature infants. *International Journal of Applied Electromagnetics and Mechanics*. 2007; 25(1–4): 469–475. <https://doi.org/10.3233/JAE-2007-751>
- Martín-Yebra A., Landreani F., Casellato C., Pavan E., Frigo C., Migeotte P.F., Caiani E. Studying heart rate variability from ballistocardiography acquired by force platform: Comparison with conventional ECG. *Proceedings of the 2015 Computing in Cardiology Conference (CinC)*. 2015. p. 929–32. <https://doi.org/10.3233/jae-2007-751>

4. Antink C.H., Mai Y., Aalto R., Brüser C., Leonhardt S., Oksala N., Vehkaoja A. Ballistocardiography can estimate beat-to-beat heart rate accurately at night in patients after vascular intervention. *IEEE Journal of Biomedical and Health Informatics*. 2020;24(8) 2230-2237. <https://doi.org/10.1109/JBHI.2020.2970298>
5. Alametsä J., Väri A., Koivuluoma M., Barna L. The potential of EMFi sensors in heart activity monitoring. *Proceedings of the 2nd OpenECG Workshop, Berlin, Germany*. 2004. <https://researchportal.tuni.fi/en/publications/the-potential-of-emfi-sensors-in-herat-activity-monitoring>
6. Hu H.F., Sun S.J., Lv R.Q., Zhao Y. Design and experiment of an optical fiber micro bend sensor for respiration monitoring. *Sensors and Actuators A: Physical*.2016;251:126–133. <https://doi.org/10.1016/j.sna.2016.10.013>
7. Brink M., Müller C.H., Schierz C. Contact-free measurement of heart rate, respiration rate, and body movements during sleep. *Behavior Research Methods*. 2006;38(3):511–521. <https://doi.org/10.3758/BF03192806>
8. Rajput J.S., Sharma M., Kumar T.S., Acharya U.R. Automated detection of hypertension using continuous wavelet transform and a deep neural network with ballistocardiography signals. *International Journal of Environmental Research and PublicHealth*.2022;19(7):4014. <https://doi.org/10.3390/ijerph19074014>
9. Etemadi M., Inan O.T., Giovangrandi L., Kovacs G.T. Rapid assessment of cardiac contractility on a home bathroom scale. *IEEE Transactions on Information Technology in Biomedicine*. 2011;15(6):864–869. <https://doi.org/10.1109/TITB.2011.2161998>
10. Carlson C., Turpin V.R., Suliman A., Ade C., Warren S., Thompson D.E. Bed-based ballistocardiography: Dataset and ability to track cardiovascular parameters. *Sensors*.2021;21(1):156. <https://doi.org/10.3390/s21010156>
11. Fariha M., Ikeura R., Hayakawa S., Tsutsumi S. Analysis of Pan-Tompkins algorithm performance with noisy ECG signals. *Journal of Physics: ConferenceSeries*.2020;1532:012022. <https://doi.org/10.1088/1742-6596/1532/1/012022>
12. Bruser C., Stadthanner K., de Waele S., Leonhardt S. Adaptive beat-to-beat heart rate estimation in ballistocardiograms. *IEEE Transactions on Information Technology in Biomedicine*. 2011;15(5):778–786. <https://doi.org/10.1109/TITB.2011.2128337>
13. Feng J., Huang W., Jiang J., Wang Y., Zhang X., Li Q., Jiao X. Non-invasive monitoring of cardiac function through ballistocardiogram: An algorithm integrating short-time Fourier transform and ensemble empirical mode decomposition. *Frontiers in Physiology*.2023;14:1201722. <https://doi.org/10.3389/fphys.2023.1201722>
14. Goodfellow I., Bengio Y., Courville A. Deep learning. *MIT Press, Cambridge*. 2016.
15. Nielsen M.A. Neural networks and deep learning. *Determination Press, San Francisco, CA, USA*. 2015. <http://neuralnetworksanddeeplearning.com>
16. Morokuma S, Saitoh T, Kanegae M, Motomura N, Ikeda S, Niizeki K. Prediction of ECG signals from ballistocardiography using deep learning for the unconstrained measurement of heartbeat intervals. *Scientific Reports*. 2025;15(1):999. <https://doi.org/10.1038/s41598-024-84049-0>