

جای‌گزینی سرو موتور به جای موتور جریان مستقیم (DC)

محمدرضا بهرامی نژاد* و متین قائم پناه

اداره تعمیرات و نگهداری ناحیه ۲، گروه صنعتی بارز، کرمان، ایران

h.zarave23@yahoo.com

چکیده: در خط تولید تایر، موتور جریان مستقیم (DC) نصب شده بر دستگاه وایندپ بید سازی به عنوان محرک اصلی نقش اجرا و موقعیت دهی را بر عهده داشت، اما قدمت دستگاه و مشکلات مکرر نگهداری، تأمین قطعات یدکی و خرابی‌های پی‌درپی همراه با کنترل موقعیت ناکافی، عملکرد تولید را تحت تأثیر قرار می‌دادند. در این مطالعه، موتور DC قدیمی با یک سرو موتور صنعتی و درایو کنترل موقعیت جای‌گزین شد تا دقت، قابلیت اطمینان و دسترس‌پذیری خط تولید ارتقاء یابد. روش کار شامل انتخاب سرو موتور مناسب براساس نیازهای گشتاور و سرعت دستگاه وایندپ، نصب انکودر و درایو مرتبط، یکپارچه‌سازی با کنترلر موجود و تنظیم پارامترهای کنترلی (PID و فید بک موقعیت) بود. پس از راه‌اندازی، عملکرد سیستم در پارامترهای کلیدی شامل دقت موقعیت دهی، تکرارپذیری، زمان راه‌افتادگی، تعداد خطاهای تولید و میانگین زمان بین خرابی‌ها (MTBF) مورد ارزیابی قرار گرفت. این جای‌گزینی به عنوان راه‌کار عملی برای افزایش بهره‌وری و قابلیت اطمینان در دستگاه‌های مرتبط با ساخت تایر معرفی می‌شود و مسیر توسعه بعدی شامل اندازه‌گیری کمی صرفه‌جویی انرژی و تحلیل اقتصادی کامل‌تر برای محاسبه دوره بازگشت سرمایه است.

واژه‌های کلیدی: سرو موتور، موتور DC، کنترلر، طوقه، کنترل موقعیت، درایو

مقدمه

در فرایند تولید تایر، یکی از مراحل کلیدی ساخت طوقه یا بید (Bead) است؛ حلقه‌ای از سیم‌های فولادی که در لبه داخلی تایر قرار می‌گیرد و نقش حیاتی در اتصال تایر به رینگ و حفظ ساختار آن در برابر فشار باد ایفا می‌کند. دستگاه وایندپ بیدسازی (Bead Winding Machine) وظیفه دارد با پیچاندن چندین رشته سیم فولادی به صورت مارپیچ و دایره‌ای، این طوقه را با دقت بالا تولید کند. این دستگاه با چرخاندن یک ماندل (Mandrel) مرکزی، سیم‌ها را به صورت یکنواخت دور آن می‌پیچد تا حلقه‌ای مقاوم و هم‌مرکز شکل گیرد. در نسخه‌های قدیمی این دستگاه، موتور جریان مستقیم (DC) به عنوان محرک اصلی برای چرخش ماندل استفاده می‌شد. با گذشت زمان، این موتورها با چالش‌هایی نظیر استهلاک بالا، نیاز مکرر به تعمیرات، دشواری در تأمین قطعات یدکی، و عدم دقت کافی در کنترل موقعیت مواجه شدند. این مشکلات نه تنها باعث کاهش بهره‌وری تولید می‌شدند، بلکه کیفیت طوقه‌های تولیدی را نیز تحت تأثیر قرار می‌دادند. نتایج نشان دادند که جای‌گزینی سرو موتور موجب افزایش قابل توجه دقت موقعیت دهی و تکرارپذیری، کاهش نیاز به نگهداری و توقفات ناگهانی، و بهبود پاسخ‌دهی دینامیکی سیستم شد. همچنین، یکپارچه‌سازی آسان‌تر با سیستم کنترل و امکان پیاده‌سازی استراتژی‌های کنترلی پیشرفته‌تر از دیگر مزایای مشاهده شده بود. چالش‌های اجرایی شامل هزینه اولیه بالاتر، نیاز به تنظیمات و تیونینگ درایو و آموزش اپراتورها برای نگهداری از سیستم جدید بود. در این پروژه، با هدف بهبود عملکرد دستگاه و افزایش دقت تولید، تصمیم به جای‌گزینی موتور DC با یک سرو موتور صنعتی گرفته شد. این جای‌گزینی، امکان کنترل دقیق‌تر موقعیت، سرعت و گشتاور را فراهم کرده و موجب کاهش توقفات ناگهانی و افزایش کیفیت محصول نهایی شده است.

نحوه کار و فرایند جای‌گزینی سرو موتور

اجرا سیستم:

۱. سروموتور، ۲. آمپلی‌فایر (درایو)، ۳. کنترل‌کننده، ۴. سیستم مانیتورینگ فرایند جای‌گزینی شامل مراحل زیر بود:

- تحلیل نیاز مکانیکی و کنترلی: ابتدا گشتاور مورد نیاز برای چرخش ماندل و وزن سیم‌ها محاسبه شد تا سرو موتور مناسب انتخاب شود.

- انتخاب سرو موتور و درایو: یک سرو موتور با انکودر دقیق و درایو قابل برنامه‌ریزی انتخاب شد که قابلیت کنترل موقعیت و سرعت با دقت بالا را داشته باشد.

- اصلاح مکانیکی دستگاه: پایه نصب موتور DC قدیمی بازطراحی شد تا با ابعاد و مشخصات سرو موتور جدید سازگار شود.

- اتصال به سیستم کنترل: سرو موتور به کنترلر مرکزی دستگاه متصل شد و پارامترهای حرکتی از طریق درایو تنظیم شدند.

- تنظیمات کنترلی و تیونینگ: با استفاده از فیدبک موقعیت و الگوریتم‌های PID، دقت چرخش و توقف در نقاط مشخص بهینه‌سازی شد.

- آزمایش و ارزیابی عملکرد: پس از راه‌اندازی، عملکرد دستگاه در تولید طوقه‌های یکنواخت، کاهش خطاهای تولید، و افزایش سرعت عملیاتی مورد بررسی قرار گرفت.

نتیجه‌گیری

جای‌گزینی سرو موتور Mitsubishi به جای موتور جریان مستقیم (DC) در دستگاه وایندپ بیدسازی، به عنوان یک اقدام مهندسی هدفمند، تأثیرات قابل توجهی در بهبود عملکرد، دقت و پایداری سیستم ایجاد کرد. بررسی‌های عملی نشان داد که سرو موتور با بهره‌گیری از سیستم فیدبک موقعیت و قابلیت کنترل دقیق سرعت، توانست چرخش ماندل را با دقت بالا و تکرارپذیری مطلوب انجام دهد؛ امری که در تولید طوقه‌های یکنواخت و باکیفیت نقش کلیدی دارد. از منظر نگهداری، حذف جاروبک‌ها و قطعات مکانیکی فرسایش‌پذیر در سرو موتور موجب کاهش چشم‌گیر نیاز به تعمیرات دوره‌ای و افزایش میانگین زمان بین خرابی‌ها (MTBF) شد. همچنین، یکپارچگی بهتر با سیستم کنترل مرکزی و امکان تنظیم پارامترهای کنترلی از طریق درایو دیجیتال، انعطاف‌پذیری بیشتری در تنظیمات عملیاتی دستگاه فراهم کرد. از نظر اقتصادی، اگرچه هزینه اولیه خرید و نصب سرو موتور بالاتر از موتور DC بود، اما کاهش توقفات تولید، افزایش کیفیت محصول نهایی، و کاهش هزینه‌های نگهداری، منجر به بازگشت سرمایه در بازه زمانی قابل قبول شد. این جای‌گزینی نه تنها موجب ارتقاء عملکرد دستگاه وایندپ شد، بلکه به عنوان یک الگوی موفق برای نوسازی سایر تجهیزات قدیمی در خطوط تولید تایر قابل تعمیم است. در نهایت، این پروژه نشان داد که استفاده از فناوری‌های نوین در اتوماسیون صنعتی، به‌ویژه در بخش‌های حساس تولید، می‌تواند نقش مهمی در افزایش بهره‌وری، کاهش ضایعات، و ارتقاء کیفیت ایفا کند.

[۲] گروه صنعتی بارز - معرفی فرایند ساخت تایر و تجهیزات مرتبط <https://barez.org>

[۳] مقاله تخصصی: تحلیل عملکرد سرو موتور در خطوط تولید تایر

[۴] مرکز مطالعات اتوماسیون صنعتی، دانشگاه صنعتی شریف، ۱۴۰۱

[۱] وبسایت رسمی - Mitsubishi Electric بخش سرو موتورهای صنعتی <https://www.mitsubishielectric.com/fa/products-solutions/factoryautomation>

استفاده از هوش مصنوعی در تشخیص عیوب تایر: گامی به سوی کارخانه هوشمند

محمدرضا حسینخانی^{۱*} و زهره حسینخانی^۲

۱- کارشناس ارشد مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران

۲- دکتری مهندسی کامپیوتر-هوش مصنوعی، دانشگاه صنعتی اصفهان، اصفهان، ایران

Imanfakhri2303@gmail.com

چکیده: با گسترش فناوری‌های دیجیتال و افزایش رقابت در صنعت تایرسازی، نیاز به سامانه‌های هوشمند برای پایش کیفیت و پیش‌بینی دوام تایر بیش از پیش احساس می‌شود.

در این پژوهش، یک مدل مبتنی بر یادگیری عمیق برای تشخیص خودکار عیوب تایر توسعه داده شد تا به‌عنوان گامی عملی در مسیر کارخانه هوشمند تایر مورد استفاده قرار گیرد. داده‌ها شامل مجموعه‌ای از تصاویر واقعی تایرهای سالم و دارای عیب بودند که تحت شرایط نوری معمول در محیط تهیه شدند. مدل انتخابی بر پایه شبکه عصبی کانولوشنی ResNet18 بوده که با استفاده از وزن‌های اولیه ImageNet با آموزش و برای طبقه‌بندی دودویی (سالم/دارای عیب) تنظیم شد. داده‌ها با نسبت ۸۰٪ آموزش و ۲۰٪ اعتبارسنجی تقسیم شدند و طی ۲۰ اپیاک با الگوریتم Adam آموزش دیدند. نتایج نشان داد مدل پیشنهادی توانست با دقت بیش از ۹۷٪ و امتیاز F1 حدود ۹۶٪ عیوب تایر را شناسایی کند. این دستاورد نشان می‌دهد که هوش مصنوعی می‌تواند با اتوماسیون فرایند بازرسی بصری، دقت کنترل کیفیت و سرعت تشخیص عیوب را افزایش داده و گامی مؤثر در جهت تحقق تولید هوشمند و تحلیل پیش‌بینانه عمر تایر باشد. به کارگیری چنین سامانه‌ای در خطوط تولید، موجب کاهش خطای انسانی و هزینه‌های بازرسی می‌شود.

واژه‌های کلیدی: عیوب تایر، هوش مصنوعی، پردازش تصویر، شبیه‌سازی، حل مسئله

مقدمه

پژوهش بخشی از مسیر حرکت صنعت تایرسازی به سمت کارخانه هوشمند تایر (Smart Tire Factory) است که در آن، پایش کیفیت، تحلیل عمر تایر و پیش‌بینی خرابی‌ها به‌صورت هوشمند و خودکار انجام می‌شود.

بخش تجربی

روش کار

در این پژوهش، یک مدل مبتنی بر یادگیری عمیق (Deep Learning) برای تشخیص خودکار عیوب سطحی تایر توسعه داده شد. مراحل انجام کار به‌صورت سیستماتیک شامل گردآوری داده، پیش‌پردازش، طراحی مدل، آموزش و ارزیابی عملکرد است که در ادامه تشریح می‌شود.

گردآوری و آماده‌سازی داده‌ها

داده‌های مورد استفاده شامل دو مجموعه تصویر بودند:

- تصاویر تایرهای سالم
- تصاویر تایرهای دارای عیب

تصاویر در شرایط نوری معمول داخل کارگاه و مراکز سرویس ثبت شدند تا مدل بتواند در محیط‌های واقعی عملکرد قابل قبولی داشته باشد. برای یکنواخت‌سازی داده‌ها، تمامی تصاویر به ابعاد 224×224 پیکسل تغییر اندازه داده شدند. به‌علاوه، به‌منظور بهره‌گیری از منابع داده عمومی و افزایش قابلیت مقایسه‌پذیری، از دیتاست زیر نیز به‌عنوان مرجع استفاده شد:

دیتاست TyreNet که شامل ۱۶۹۸ تصویر تایر (۸۶۶ تصویر دارای عیب) است [۱۰]. بدین ترتیب، مدل توانایی تعمیم به داده‌های عمومی را نیز خواهد داشت. ترکیب داده‌های واقعی و عمومی، موجب افزایش توانایی مدل در تعمیم به شرایط نوری، زاویه دید و بافت‌های متفاوت شد.

تقسیم‌بندی داده‌ها

مجموعه داده‌ها به دو بخش آموزش (Training) و اعتبارسنجی (Validation)

کنترل کیفیت تایر یکی از مهم‌ترین مراحل در فرایند تولید و خدمات پس از فروش در صنعت تایرسازی است در هر یک از مراحل تولید تایر، احتمال بروز عیوب مختلفی وجود دارد. در روش‌های سنتی، تشخیص این عیوب بر پایه بازرسی چشمی یا آزمون‌های مکانیکی انجام می‌شود که افزون بر زمان‌بر بودن، دقت محدودی دارد و به‌شدت وابسته به نیروی انسانی است. با ظهور فناوری‌های هوش مصنوعی، یادگیری ماشین و پردازش داده‌های صنعتی، امکان تحلیل خودکار حجم عظیمی از داده‌های فرایند و عملکرد فراهم شده است [۱ تا ۳]. در چنین بستری، هدف از این پژوهش توسعه مدلی هوشمند است که با یادگیری از داده‌های تولیدی و میدانی، بتواند به‌صورت خودکار عیوب تایر را شناسایی کند. این رویکرد، گامی عملی در مسیر پیاده‌سازی مفهوم «کارخانه هوشمند تایر» محسوب می‌شود که در آن داده، تصمیم‌گیری و بهینه‌سازی، همگی مبتنی بر الگوریتم‌های هوش مصنوعی انجام می‌گیرد [۴، ۵ و ۹].


عیوب تایر به دو دسته عیوب تولیدی که حین تولید رخ می‌دهند و عیوب سرویس که حین کارکرد تایر در شرایط واقعی رخ می‌دهند تقسیم می‌گردند و از مدل هوش مصنوعی در صورت وجود داده کافی و آموزش مناسب مدل می‌توان برای تشخیص و متعاقباً انجام اقدام اصلاحی استفاده کرد. عیوبی مانند ترک‌های سطحی، جدایش لایه‌ها و سایش نامتوازن نه تنها بر عملکرد تایر اثر منفی می‌گذارند بلکه می‌توانند خطرات جدی ایمنی ایجاد کنند. در سال‌های اخیر، پیشرفت سریع در حوزه یادگیری عمیق (Deep Learning) و بینایی ماشین (Machine Vision) امکان تحلیل خودکار تصاویر صنعتی را فراهم کرده است. این فناوری‌ها می‌توانند در لحظه الگوهای ظریف سطح تایر را شناسایی کرده و وجود عیب را با دقت بالا تشخیص دهند [۶ تا ۸].

هدف از این پژوهش، توسعه مدلی کارآمد برای تشخیص خودکار عیوب در تایر با استفاده از شبکه‌های عصبی کانولوشنی (CNN) است. با بهره‌گیری از ترکیب داده‌های واقعی و دیتاست‌های مرجع، و اعمال تکنیک‌های افزایش داده (Data Augmentation)، تلاش شده است تا مدلی با دقت بالا و قابلیت تعمیم مناسب ایجاد شود. این


جدول ۱- عملکرد مدل بر روی مجموعه اعتبارسنجی

مقدار	معیار
۰/۹۷	دقت (Accuracy)
۰/۹۶	دقت طبقه‌بندی (Precision)
۰/۹۷	بازخوانی (Recall)
۰/۹۷	امتیاز F1

نتایج بصری تحلیل منحنی‌های دقت و خطا نشان دادند که پس از حدود ۲۰ اپیاک، مدل به پایداری کامل در یادگیری رسید و هیچ نشانه‌ای از بیش‌برازش مشاهده نشد. استفاده از تکنیک‌های افزایش داده مانند چرخش تصادفی و تغییر روشنایی موجب شد مدل نسبت به تغییرات زاویه و نور مقاوم‌تر شود.




شکل ۲- نمودار دقت مجموعه اعتبارسنجی در طول اپیاک‌ها. افزایش مستمر دقت و رسیدن به مقدار نهایی ۹۷٪ نشان‌دهنده توانایی مدل در تعمیم به داده‌های دیده‌نشده است.



شکل ۳- نمودار تغییرات تابع خطای آموزش و اعتبارسنجی طی اپیاک‌های مختلف. کاهش پایدار loss نشان‌دهنده یادگیری مؤثر مدل و جلوگیری از بیش‌برازش است.

مقایسه با مدل‌های مشابه مانند VGG16 و EfficientNet نشان داد که ResNet18 با پیچیدگی کمتر، بهترین توازن میان دقت و سرعت پردازش را ارائه می‌دهد. همچنین آزمایش با داده‌های مرجع TyreNet نشان داد که مدل توانایی تعمیم‌پذیری مناسبی به تصاویر غیر آشنا دارد.



شکل ۴- نمودار ROC و مقدار AUC برای مجموعه اعتبارسنجی. شیب نزدیک به گوشه بالا-چپ و مقدار AUC بالا نشان‌دهنده عملکرد قوی مدل در تمایز میان کلاس‌های سالم و ترک‌دار است.

تقسیم شدند تا از بیش‌برازش جلوگیری شود. نسبت تفکیک داده‌ها برابر ۸۰٪ برای آموزش و ۲۰٪ برای اعتبارسنجی در نظر گرفته شد. تصاویر مجموعه اعتبارسنجی در فرایند آموزش دیده نشدند و صرفاً برای ارزیابی نهایی مدل به کار رفتند.

پیش‌پردازش و افزایش داده

برای افزایش مقاومت مدل در برابر تغییرات محیطی و بهبود تعمیم‌پذیری، مجموعه‌ای از تبدیلات تصادفی بر روی تصاویر اعمال شد، از جمله: چرخش تصادفی تا $\pm 10^\circ$ درجه، وارون‌سازی افقی (Horizontal Flip)، تغییر روشنایی و کنتراست، نرمال‌سازی با میانگین و انحراف معیار استاندارد [۰/۴۸۵، ۰/۴۵۶]، [۰/۲۲۹، ۰/۲۲۴] و [۰/۲۲۵، ۰/۲۲۴] مطابق با مدل‌های پیش‌آماده ImageNet این عملیات باعث شد که مدل بتواند در مواجهه با داده‌های جدید و متنوع، عملکرد پایداری داشته باشد.

طراحی معماری مدل

برای انجام طبقه‌بندی دودویی (سالم / ترک‌دار)، از شبکه عصبی کانولوشنی ResNet18 به‌عنوان مدل پایه استفاده شد. این شبکه به‌دلیل عمق مناسب و بهره‌گیری از اتصالات میان‌گذر (Skip Connections)، توانایی بالایی در استخراج ویژگی‌های پیچیده از تصاویر صنعتی دارد. وزن‌های اولیه مدل از مجموعه ImageNet بارگذاری شدند و سپس لایه نهایی آن با دو نورون خروجی جای‌گزین شد تا طبقه‌بندی دوکلاسه انجام گیرد. در ادامه، تمام لایه‌ها برای داده‌های جدید بازآموزی (Fine-Tuning) شدند تا ویژگی‌های مرتبط با الگوهای ترک در تایر به‌طور دقیق‌تر شناسایی شوند.

آموزش مدل


فرایند آموزش با استفاده از تابع هزینه Cross-Entropy Loss برای مسئله دوکلاسه و الگوریتم بهینه‌سازی Adam با نرخ یادگیری $1e-4$ انجام شد. تعداد کل تکرارها (Epochs) ۲۰ اپیاک در نظر گرفته شد تا مدل به همگرایی برسد. در پایان هر اپیاک، عملکرد مدل بر مجموعه اعتبارسنجی ارزیابی و بهترین نسخه مدل براساس بالاترین دقت ذخیره شد.

ارزیابی مدل

پس از اتمام آموزش، عملکرد مدل با شاخص‌های کمی زیر مورد ارزیابی قرار گرفت: دقت کلی (Accuracy)، دقت طبقه‌بندی (Precision)، بازخوانی (Recall)، امتیاز (F1-Score) افزون‌بر مقادیر عددی، نمودارهای تغییرات دقت و خطا در طول اپیاک‌ها (Accuracy & Loss Curves) ترسیم شدند تا روند همگرایی مدل و پایداری آموزش بررسی شود.

نتیجه‌ها و بحث

مدل توسعه‌یافته بر پایه شبکه ResNet18 پس از آموزش ۲۰ اپیاک به همگرایی رسید و دقت کلی مدل در مجموعه اعتبارسنجی به ۹۷ درصد رسید. معیارهای دیگر عملکرد نیز نشان دادند که مدل در تشخیص تایرهای سالم و ترک‌دار به‌طور متوازن عمل کرده است (طبق جدول ۱).



شکل ۱- ماتریس درهم‌ریختگی مدل برای مجموعه اعتبارسنجی. سلول‌های قطری نمایانگر تعداد نمونه‌های صحیح طبقه‌بندی‌شده و سلول‌های خارج از قطر خطاهای مدل را نشان می‌دهند.

تست سرعت و دوام و ... نیز آموزش داد. و از قابلیت‌های خیره‌کننده آن در تخمین عمر و پیش‌بینی حالات خرابی نیز بهره برد
مدل در صورت وجود دیتا و آموزش می‌تواند با تحلیل داده‌های ذکرشده، زمان تقریبی کاهش کارایی تایر تا مرز ایمنی را برآورد کند. این قابلیت امکان پیاده‌سازی نگهداری پیش‌بینانه در سیستم‌های پایش تایر خودروهای متصل را فراهم می‌کند.
این موضوع بیانگر آن است که توسعه مدل‌های چندمنبعی (Multimodal AI Models) می‌تواند مسیر ارتقای بعدی این سیستم باشد [۱۰]

این نتایج بیانگر آن است که شبکه‌های عصبی کانولوشنی می‌توانند به‌طور مؤثر در سیستم‌های بازرسی خودکار تایر جای‌گزین بازرسی انسانی شوند. در صورت ترکیب این روش با داده‌های حسی (سنسور فشار، دما و لرزش)، می‌توان از آن برای تحلیل پیش‌بینانه عمر تایر و پایش سلامت در خودروهای متصل نیز بهره گرفت.
مدل هوش مصنوعی را می‌توان با داده‌های دیگری شامل پارامترهای فرایندی مانند فشار و دمای پخت، نتایج x-ray، ترکیب مواد، زمان اختلاط، ضخامت اجزا و نیز داده‌های عملکردی مانند میزان سایش، نتایج بالانس و یونیفورمیتی، نتایج

مراجع

- [1] Chen, J., Li, A., Zheng, F., Chen, S., He, W., & Zhang, G. (2023). Research on tire crack detection using image deep learning method. Scientific Reports.
- [2] Cozma, A., Harris, L., Qi, H., Ji, P., Guo, W., & Yuan, S. (2024). Defect Detection in Tire X-Ray Images: Conventional Methods Meet Deep Structures. (arXiv preprint).
- [3] Karkaria, V., Chen, J., Luey, C., Siuta, C., Lim, D., Radulescu, R., & Chen, W. (2024). A Digital Twin Framework Utilizing Machine Learning for Robust Predictive Maintenance: Enhancing Tire Health Monitoring.
- [4] Kim, et al. (2023). Predicting the Wear Amount of Tire Tread Using 1D-CNN. PMC (Journal).
- [5] Li, Y., & others. (2024). Tire wear monitoring using feature fusion and CatBoost classifier. Springer Journal.
- [6] Poling Group. (2022). Deep Learning for Visual Inspection and Classification of Tire Defects. (Conference Paper).
- [7] Samatas, G. G., Moumgiakmas, S. S., & Papakostas, G. A. (2021). Predictive Maintenance – Bridging Artificial Intelligence and IoT. (arXiv).
- [8] Survey: Zhu, T., Ran, Y., Zhou, X., & Wen, Y. (2019). A Survey of Predictive Maintenance: Systems, Purposes and Approaches. (arXiv).
- [9] "Revolutionizing Tire Quality Control: AI's Impact on Research and Industry." (2023). Applied Sciences (MDPI).
- [10] <https://data.mendeley.com/datasets/32b5vfj6tc/1>.