

چکیده

بتن به عنوان پر مصرف ترین ماده در ساخت سازه‌های مختلف، از اهمیت فنی و اقتصادی زیادی برخوردار می‌باشد. برای تولید بتن روش‌های استاندارد گوناگونی معرفی شده که نیازمند انجام آزمایش‌های پر هزینه و زمان‌بر هستند. به منظور کاهش زمان و هزینه‌های فوق‌الذکر، در کنار روش‌های مرسوم و سنتی، می‌توان از قابلیت‌های علم داده مانند الگوریتم‌های یادگیری ماشین برای پیش‌بینی خواص گوناگون مصالح بر اساس داده‌های موجود بهره‌گرفت. در این پژوهش روابط بین متغیرهای مؤثر در تولید بتن و پیش‌بینی خواص بتن با استفاده از علم داده، مورد بررسی قرار گرفته است. بدین منظور با جمع‌آوری داده‌های مختلف انواع طرح‌های مخلوط بتن و اصلاح مجموعه داده‌ها، از الگوریتم‌های یادگیری ماشین برای پیش‌بینی خواص بتن استفاده گردید. نتایج کلی حاصل که صرفاً بر پایه آشکار سازی اطلاعات در الگوهای پنهان داده‌ها بدست آمدند، توافقی کاملی با حقایق موجود در فناوری بتن دارند. با افزایش مقدار نسبت آب به مواد سیمانی، مقاومت بتن کاهش می‌یابد. نسبت مقاومت کششی به مقاومت فشاری بتن تقریباً برابر $0/08$ می‌باشد. همچنین با افزایش مقاومت فشاری بتن این نسبت کاهش پیدا می‌کند. به عنوان نمونه ای دیگر این که با افزایش سن و عیار سیمان در مخلوط بتن، مقاومت آن افزایش می‌یابد.

هدف این تحقیق نمایش توانمندی علم داده برای کاربرد در مطالعه و بررسی مصالح بتنی است. در این پژوهش از روش‌های مختلف یادگیری ماشین برای پیش‌بینی خواص بتن استفاده شده است و نتایج به دست آمده برای اهداف طراحی سازه‌های بتنی قابل قبول هستند. با گسترش بانک داده‌ها می‌توان این روش را توسعه داد و در شاخه‌های مختلف مهندسی عمران از آن استفاده نمود.

واژه‌های کلیدی: علم داده، الگوریتم‌های یادگیری ماشین، خواص مکانیکی بتن، مجموعه داده‌ی انواع مخلوط بتن

فهرست مطالب

۱	فصل ۱: مقدمه
۲	۱-۱- عنوان تحقیق.....
۲	۲-۱- بیان مسأله.....
۲	۳-۱- ضرورت تحقیق.....
۳	۴-۱- هدف.....
۳	۵-۱- فصول پژوهش.....

۵	فصل ۲: مروری بر ادبیات موضوع
۶	۱-۲- مقدمه.....
۶	۲-۲- تاریخچه موضوع.....
۸	۳-۲- تعریف علم داده.....
۹	۴-۲- متخصص علم داده.....
۱۰	۵-۲- تاریخچه اهمیت یافتن داده.....
۱۲	۶-۲- یادگیری ماشین.....
۱۵	۷-۲- انواع یادگیری ماشین.....
۱۵	۱-۷-۲- یادگیری نظارت شده.....
۱۶	۲-۷-۲- یادگیری نظارت نشده.....
۱۷	۳-۷-۲- یادگیری تقویتی.....
۱۷	۴-۷-۲- یادگیری عمیق.....
۱۸	۸-۲- روند تکامل انواع روش‌های یادگیری ماشین.....
۲۰	۹-۲- اهمیت آمار در یادگیری ماشین.....
۲۰	۱۰-۲- مراحل پیاده سازی یادگیری ماشین.....
۲۰	۱-۱۰-۲- تمیزکاری داده.....
۲۱	۲-۱۰-۲- تشخیص نوع داده.....
۲۱	۳-۱۰-۲- مدل سازی مبتنی بر یادگیری ماشین.....
۲۲	۴-۱۰-۲- ارزیابی مدل ساخته شده.....
۲۳	۵-۱۰-۲- کاربرد مدل های مبتنی بر یادگیری ماشین برای پیش بینی.....
۲۳	۶-۱۰-۲- استفاده از یادگیری ماشین در علم عمران.....

۲۵	فصل ۳: روش تحقیق
۲۶	۱-۳- مقدمه.....
۲۷	۲-۳- نحوه جمع آوری داده.....
۲۸	۳-۳- مشکلات جمع آوری داده.....
۲۹	۴-۳- مجموعه داده اصلی.....

- ۳-۵- نرم افزارهای یادگیری ماشین..... ۳۱
- ۳-۶- نرم افزار منتخب برای اجرای مدل سازی..... ۳۳
- ۳-۷- الگوریتم های مدل سازی..... ۳۷
- ۳-۱- انواع الگوهای مدل سازی..... ۳۸

فصل ۴: نتایج و تفسیر آن ها

- ۴۲
- ۴-۱- مقدمه..... ۴۳
- ۴-۲- الگوی شماره ی ۱..... ۴۴
- ۴-۲-۱- نمودار پراکندگی..... ۴۴
- ۴-۲-۲- برازش خطی..... ۴۸
- ۴-۲-۳- همبستگی متغیرها..... ۴۹
- ۴-۲-۴- شبکه عصبی..... ۴۹
- ۴-۲-۵- دسته بندی مقاومت فشاری..... ۵۱
- ۴-۲-۶- درخت تصمیم..... ۵۲
- ۴-۳- الگوی شماره ۲..... ۵۴
- ۴-۳-۱- نمودار پراکندگی..... ۵۴
- ۴-۳-۲-۳-۳-۴- برازش خطی..... ۵۷
- ۴-۳-۳- همبستگی متغیرها..... ۵۸
- ۴-۳-۴- شبکه عصبی..... ۵۸
- ۴-۳-۵- درخت تصمیم..... ۶۰
- ۴-۴- الگوی شماره ۳..... ۶۱
- ۴-۴-۱- نمودار پراکندگی..... ۶۲
- ۴-۴-۲- برازش خطی..... ۶۵
- ۴-۴-۳- همبستگی متغیرها..... ۶۶
- ۴-۴-۴- شبکه عصبی..... ۶۶
- ۴-۴-۵- درخت تصمیم..... ۶۸
- ۴-۵- الگوی شماره ۴..... ۷۰
- ۴-۵-۱- نمودار پراکندگی..... ۷۱
- ۴-۵-۲- برازش خطی..... ۷۲
- ۴-۵-۳- همبستگی متغیرها..... ۷۲
- ۴-۵-۴- شبکه عصبی..... ۷۳
- ۴-۵-۵- درخت تصمیم..... ۷۶
- ۴-۶- الگوی شماره ۵..... ۷۷
- ۴-۶-۱- نمودار پراکندگی..... ۷۸
- ۴-۶-۲- خوشه بندی..... ۷۹
- ۴-۶-۳- برازش خطی..... ۸۱

۸۱	۴-۶-۴- همبستگی متغیرها.....
۸۲	۴-۶-۵- شبکه عصبی.....
۸۳	۴-۶-۶- درخت تصمیم.....
۸۶	۴-۶-۷- الگوی شماره ۶.....
۸۶	۴-۶-۸- نمودار پراکندگی.....
۸۹	۴-۶-۹- خوشه بندی.....
۹۰	۴-۶-۱۰- برازش خطی.....
۹۱	۴-۶-۱۱- همبستگی متغیرها.....
۹۱	۴-۶-۱۲- شبکه عصبی.....
۹۳	۴-۶-۱۳- درخت تصمیم.....
۹۵	۴-۶-۷- الگوی شماره ۷.....
۹۶	۴-۷-۱- شبکه عصبی برای پیش بینی مقدار نسبت آب به سیمان.....
۹۷	۴-۷-۲- شبکه عصبی برای پیش بینی مقدار سیمان.....
۹۹	۴-۷-۳- شبکه عصبی برای پیش بینی مقدار ماسه.....
۱۰۰	۴-۷-۴- شبکه عصبی برای پیش بینی مقدار شن.....
۱۰۲	۴-۷-۵- پیش بینی نهایی.....
۱۰۳	۴-۸-۱- الگوی شماره ۸.....
۱۰۳	۴-۸-۱- رابطه مقاومت فشاری و مقاومت کششی.....
۱۰۴	۴-۸-۲- رابطه مقاومت فشاری و ضریب ارتجاعی.....

فصل ۵: جمع بندی و پیشنهادها

۱۰۶	۵-۱- مقدمه.....
۱۰۷	۵-۲- جمع بندی.....
۱۰۹	۵-۳- پیشنهادها.....

۱۱۰	مراجع
-----	-------

فهرست اشکال

- شکل (۱-۳) جریان کاری اجرای پژوهش..... ۲۶
- شکل (۲-۳) دو نما از قسمتی از بانک داده اصلی..... ۳۰
- شکل (۳-۳) رابط کاربری نرم افزار مورد استفاده..... ۳۴
- شکل (۴-۳) مجموعه عملگرهای اصلی نرم افزار RapidMiner..... ۳۵
- شکل (۵-۳) نمونه ای از متغیرهای در دسترس برای الگوریتم شبکه عصبی..... ۳۶
- شکل (۶-۳) محیط اسکریپت نویسی در برنامه RapidMiner..... ۳۷
- شکل (۱-۴) متغیرهای الگوی شماره ۱..... ۴۴
- شکل (۲-۴) نمودار نسبت آب به سیمان و مقاومت فشاری بتن..... ۴۵
- شکل (۳-۴) نمودار نسبت آب به سیمان و مقاومت فشاری بتن برای بازه بیشتر از ۰/۳۵..... ۴۶
- شکل (۴-۴) نمودار نسبت آب به سیمان و مقاومت فشاری بتن برای بازه کمتر از ۰/۳۵..... ۴۷
- شکل (۵-۴) معماری شبکه عصبی الگوی شماره ۱..... ۵۰
- شکل (۶-۴) درخت تصمیم الگوی شماره ۱..... ۵۲
- شکل (۷-۴) نمودار مربوطه در مقاله برای ارزیابی اثر سن و نسبت آب به سیمان در مقاومت فشاری [51]. ۵۳
- شکل (۸-۴) متغیرهای الگوی شماره ۲..... ۵۴
- شکل (۹-۴) نمودار نسبت آب به سیمان به ضریب ارتجاعی..... ۵۴
- شکل (۱۰-۴) نمودار چگالی بتن تازه و ضریب ارتجاعی..... ۵۵
- شکل (۱۱-۴) نمودار نسبت چگالی بتن تازه به ضریب ارتجاعی برای مقادیر چگالی بیشتر ۲۱۰۰ کیلوگرم بر مترمکعب..... ۵۶
- شکل (۱۲-۴) معماری شبکه عصبی مناسب برای الگوی شماره ۲..... ۵۹
- شکل (۱۳-۴) درخت تصمیم الگوی شماره ۲..... ۶۰
- شکل (۱۴-۴) متغیرهای الگوی شماره ۳..... ۶۱
- شکل (۱۵-۴) نمودار نسبت آب به سیمان و مقاومت کششی در الگوی شماره ۳..... ۶۲
- شکل (۱۶-۴) نمودار چگالی ویژه بتن تازه و مقاومت کششی..... ۶۳
- شکل (۱۷-۴) نمودار چگالی بتن تازه و مقدار مقاومت کششی برای محدوده چگالی بیش از ۲۱۰۰ کیلوگرم بر مترمکعب..... ۶۴
- شکل (۱۸-۴) معماری شبکه عصبی الگوی شماره ۳..... ۶۷
- شکل (۱۹-۴) درخت تصمیم الگوی شماره ۳..... ۶۹
- شکل (۲۰-۴) متغیرهای الگوی شماره ۴..... ۷۰
- شکل (۲۱-۴) نمودار نسبت آب به سیمان و اسلامپ..... ۷۱
- شکل (۲۲-۴) معماری مناسب شبکه عصبی الگوی شماره ۴..... ۷۴

- شکل (۴-۲۳) معماری شبکه عصبی الگوی شماره ۴ با روان کننده..... ۷۵
- شکل (۴-۲۴) متغیرهای الگوی شماره ۵..... ۷۷
- شکل (۴-۲۵) نمودار ماده فوق روان کننده و مقاومت فشاری..... ۷۸
- شکل (۴-۲۶) ساختار خوشه‌بندی الگوی شماره ۵..... ۷۹
- شکل (۴-۲۷) خوشه‌بندی داده الگوی شماره ۵..... ۸۰
- شکل (۴-۲۸) معماری مناسب شبکه عصبی برای الگوی شماره ۵..... ۸۲
- شکل (۴-۲۹) درخت تصمیم الگوی شماره ۵..... ۸۴
- شکل (۴-۳۰) متغیرهای الگوی شماره ۶..... ۸۶
- شکل (۴-۳۱) نمودار نسبت ماسه به شن و مقاومت فشاری..... ۸۷
- شکل (۴-۳۲) نمودار دسته اول نسبت ماسه به شن و مقاومت فشاری..... ۸۸
- شکل (۴-۳۳) ساختار خوشه‌بندی الگوی شماره ۶..... ۸۹
- شکل (۴-۳۴) خوشه‌بندی الگوی شماره ۶..... ۸۹
- شکل (۴-۳۵) معماری مناسب شبکه عصبی الگوی شماره ۶..... ۹۲
- شکل (۴-۳۶) درخت تصمیم الگوی شماره ۶..... ۹۴
- شکل (۴-۳۷) متغیرهای الگوی شماره ۷..... ۹۵
- شکل (۴-۳۸) معماری مناسب شبکه عصبی الگوی شماره ۷ پیش‌بینی نسبت آب به سیمان..... ۹۷
- شکل (۴-۳۹) معماری مناسب شبکه عصبی الگوی شماره ۷ پیش‌بینی سیمان..... ۹۸
- شکل (۴-۴۰) معماری مناسب شبکه عصبی الگوی شماره ۷ پیش‌بینی مقدار ماسه..... ۱۰۰
- شکل (۴-۴۱) معماری مناسب شبکه عصبی الگوی شماره ۷ پیش‌بینی مقدار شن..... ۱۰۱
- شکل (۴-۴۲) نمودار مقاومت کششی بر حسب مقاومت فشاری..... ۱۰۳

فهرست جداول

جدول (۱-۴) جدول علائم اختصاری.....	۴۳
جدول (۲-۴) همبستگی متغیرهای الگوی شماره ۱.....	۴۹
جدول (۳-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۱.....	۴۹
جدول (۴-۴) جدول ورودی‌های الگوی شماره ۱.....	۵۰
جدول (۵-۴) نتیجه پیش‌بینی شبکه عصبی.....	۵۱
جدول (۶-۴) جدول همبستگی متغیرهای الگوی شماره ۲.....	۵۸
جدول (۷-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۲.....	۵۸
جدول (۸-۴) جدول داده موردنظر برای پیش‌بینی مقدار ضریب ارتجاعی.....	۵۹
جدول (۹-۴) مقدار پیش‌بینی شده ضریب ارتجاعی.....	۵۹
جدول (۱۰-۴) همبستگی متغیرهای الگوی شماره ۳.....	۶۶
جدول (۱۱-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۳.....	۶۷
جدول (۱۲-۴) جدول ورودی پیش‌بینی شبکه عصبی الگوی شماره ۳.....	۶۸
جدول (۱۳-۴) پیش‌بینی شبکه عصبی الگوی شماره ۳.....	۶۸
جدول (۱۴-۴) همبستگی متغیرهای الگوی شماره ۴.....	۷۳
جدول (۱۵-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۳.....	۷۳
جدول (۱۶-۴) ورودی شبکه عصبی الگوی شماره ۴.....	۷۴
جدول (۱۷-۴) پیش‌بینی مقدار اسلامپ شبکه عصبی.....	۷۴
جدول (۱۸-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۴ با روان کننده.....	۷۵
جدول (۱۹-۴) ورودی شبکه عصبی الگوی شماره ۴ با روان کننده.....	۷۶
جدول (۲۰-۴) جدول پیش‌بینی شبکه عصبی.....	۷۶
جدول (۲۱-۴) همبستگی متغیرهای الگوی شماره ۵.....	۸۱
جدول (۲۲-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۵.....	۸۲
جدول (۲۳-۴) جدول ورودی شبکه عصبی الگوی شماره ۵.....	۸۳
جدول (۲۴-۴) جدول پیش‌بینی شبکه عصبی الگوی شماره ۵.....	۸۳
جدول (۲۵-۴) جدول همبستگی متغیرهای الگوی شماره ۶.....	۹۱
جدول (۲۶-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۶.....	۹۲
جدول (۲۷-۴) جدول ورودی پیش‌بینی الگوی شماره ۶.....	۹۳
جدول (۲۸-۴) جدول نتیجه پیش‌بینی شبکه عصبی الگوی شماره ۶.....	۹۳
جدول (۲۹-۴) جدول اولیه الگوی معکوس شماره ۷.....	۹۶
جدول (۳۰-۴) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۷ پیش‌بینی نسبت آب به سیمان.....	۹۶

- جدول (۴-۳۱) جدول پیش‌بینی مرحله اول نسبت به آب به سیمان.....۹۷
- جدول (۴-۳۲) جدول اولیه پیش‌بینی مقدار سیمان در الگوی شماره ۷.....۹۷
- جدول (۴-۳۳) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۷ پیش‌بینی مقدار سیمان.....۹۸
- جدول (۴-۳۴) جدول پیش‌بینی مقدار سیمان الگوی شماره ۷.....۹۸
- جدول (۴-۳۵) جدول اولیه پیش‌بینی مقدار ماسه در الگوی شماره ۷.....۹۹
- جدول (۴-۳۶) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۷ پیش‌بینی مقدار ماسه.....۹۹
- جدول (۴-۳۷) مقدار پیش‌بینی شده برای ماسه در الگوی شماره ۷.....۱۰۰
- جدول (۴-۳۸) جدول اولیه پیش‌بینی مقدار شن در الگوی شماره ۷.....۱۰۱
- جدول (۴-۳۹) جدول تحلیل حساسیت شبکه عصبی الگوی شماره ۷ پیش‌بینی مقدار شن.....۱۰۱
- جدول (۴-۴۰) مقدار پیش‌بینی شده برای شن در الگوی شماره ۷.....۱۰۲
- جدول (۴-۴۱) جدول نهایی الگوی شماره ۷.....۱۰۲

فصل ١:

مقدمه

۱-۱- عنوان تحقیق

در این پژوهش سعی بر این است که برخی خواص مخلوط‌های بتنی را که می‌توان با انجام آزمایش در آزمایشگاه مورد بررسی قرار داد با استفاده الگوریتم‌های یادگیری ماشین استخراج کرد. این امر بررسی مخلوط‌های بتنی را بسیار تسهیل می‌بخشد.

۱-۲- بیان مسأله

آزمایش‌های بتنی در آزمایشگاه بدین صورت بوده است که در آن پژوهشگر با ساختن نمونه از طرح مخلوط مورد نظر خود و اجرای آزمایش مربوطه ویژگی‌های طرح مخلوط رو مورد بررسی قرار می‌دهد. اما پژوهشگر می‌تواند با استفاده از داده‌ی موجود از آزمایش‌های قبلی خود یا دیگر پژوهشگران استفاده کند و با پیاده سازی الگوریتم مناسب از مجموعه الگوریتم‌های موجود در هوش مصنوعی، یادگیری ماشین را روی داده اجرا کند و مدل یادگیری شده‌ی بسازد. سپس از مدل مبتنی بر یادگیری خود نتایج مورد نیاز خود را به دست آورد.

۱-۳- ضرورت تحقیق

در پروژه‌های عمرانی بنا به محاسبات صورت گرفته نیاز به بتن با مشخصات فیزیکی خاصی است که طبق این مشخصات طرح مخلوط بتن به دست می‌آید. سپس طرح مخلوط به دست آمده در آزمایشگاه مورد آزمایش قرار گرفته و صحت محاسبات سنجیده می‌شود و در نهایت در پروژه مورد نظر مورد استفاده قرار می‌گیرد. اما این فرآیند، زمان بر و هزینه بر است. در صورتی که نیاز باشد نتایج آزمایش در زمان اندکی به دست بیاید یا شرایط آزمایش نباشد راه حل چیست؟ در برخی موارد مهندسین به دنبال بتن با ویژگی خاصی هستند که تا کنون ساخته نشده است، یافتن طرح مخلوط بتن با ویژگی مورد نظر نیازمند آزمون و خطا و آزمایش مکرر نمونه‌های مختلف مخلوط بتنی است. حال در صورتی که شرایط برای آزمون و خطا فراهم نباشد و یا محدودیت‌های برای آزمایش وجود داشته باشد این امر نیست با بستن روبرو می‌شود، از این رو در این پژوهش راه حل مبتنی بر یادگیری ماشین در سیستم‌های کامپیوتری ارائه می‌شود که موارد

فوق و بسیاری از مشکلات مشابه راه تا حد زیادی حل خواهد کرد.

۱-۴- هدف

هدف اصلی این پژوهش این است که آزمایش‌هایی که به صورت متداول در آزمایشگاه‌ها اجرا می‌شده است را به صورت یادگیری ماشین مبتنی بر هوش مصنوعی اجرا کند و در نهایت نتایج حاصل را با روش‌های سنتی آزمایشگاهی مقایسه کند. پژوهشگر در این پژوهش قصد دارد که تا دستاورد های واضح و متداولی که در علم طرح مخلوط بتن تا کنون وجود داشته است را با یادگیری ماشین اثبات کند و نشان دهد که دستاوردهای حاصل از تحلیل های مبتنی بر هوش مصنوعی همان مفاهیم را عرضه می‌کند و این خود نمایش صحت این روش نوین در طرح مخلوط بتن است. پژوهشگر در این فرآیند فقط دسترسی به داده دارد و با استفاده از داده اطلاعات را استخراج خواهد کرد. از سوی دیگر در این پژوهش بر اساس الگوریتم‌های مناسب مدلسازی مناسب برای به دست آوردن تحلیل یا پیش بینی صحیح از خصوصیات طرح مخلوط ارائه می‌گردد تا دیگر پژوهشگران با تکیه بر یادگیری ماشین و الگوریتم‌های هوش مصنوعی در کنار نوآوری های خود دستاوردهای جدیدی در علم طرح مخلوط بتن به رقم بزنند. به کار گیری علم یادگیری ماشین موجب می‌شود که در نهایت باعث به وجود آمدن تحول بزرگی در مهندسی عمران و علم طرح مخلوط بتن خواهد شد. دیگر مهندسان نیاز به طرح مخلوط یا طراحی بتن با ویژگی مورد نظر ندارد و می‌توانند با فقط دانستن ویژگی های مورد نظر بتن طرح مخلوط خود را از سیستم یادگیری شده به دست بیاورند.

۱-۵- فصول پژوهش

پژوهش پیش رو متمرکز بر استفاده از هوش مصنوعی و الگوریتم‌های یادگیری ماشین برای پیش‌بینی برخی از خواص مخلوط‌های بتنی است. در فصل دوم خلاصه‌ای از پیشینه موضوع و تاریخچه‌ای از علم داده و یادگیری ماشین بیان خواهد شد. در این فصل نحوه و دلیل ایجاد علم داده ذکر می‌گردد و مشخص علم داده توصیف می‌شود. همچنین مفاهیم علم داده و روش‌های پیاده سازی آن بیان می‌شود. در ادامه فصل دوم روش‌های یادگیری ماشین نیز به صورت موجز نیز اشاره می‌شود.

در فصل سوم روش کار بیان خواهد شد. در این فصل روش جمع آوری داده و مشکلاتی پژوهشگر که در این

فرآیند روبرو شد ذکر می‌گردد. نرم افزارهای موجود در زمینه پژوهش مقایسه می‌گردد و نرم افزار منتخب و مناسب معرفی می‌شود. سپس اصول مدلسازی که ذکر می‌شود. برای مدلسازی متغیرها گروه بندی مشخص می‌شوند که نتیجه این امر ایجاد ۸ سناریو مدلسازی خواهد بود. در این سناریو با استفاده از الگوریتم‌های مشخص مدلسازی اجرا می‌شود.

در فصل چهارم نتایج به دست آمده از مدل‌سازی‌های اجرا شده ذکر خواهد گردید. در این فصل تمامی نتایج اعم از نمودار، جدول، شکل و رابطه جبری درج و در هر قسمت توضیح کمی و کیفی مربوطه نیز بیان خواهد شد. هم‌چنین نتایج به دست آمده با مقالات یا پژوهش‌های مرتبط مقایسه می‌شوند.

و در نهایت در فصل پنجم نتیجه‌گیری کلی و ادامه راه برای پژوهشگران به صورت خلاصه ذکر خواهد شد.

فصل ۲:

مروری بر ادبیات موضوع

۲-۱- مقدمه

هدف از این فصل مروری بر پیشینه تحقیق، بررسی و طبقه‌بندی یافته‌های تحقیقات دیگر محققان در سطح دنیا و تعیین و شناسایی خلاء های تحقیقاتی است.

۲-۲- تاریخچه موضوع

هر چند در بدو امر به نظر می‌رسد علم‌داده دانش جدیدی است، اما شواهد تاریخی نشان می‌دهد این علم پیشینه‌ای دیرینه داشته و وجود ضمنی آن به سال‌های بسیار دور و حتی به دوران قبل از ناپلئون بناپارت باز می‌گردد، چنان‌که شواهد موجود نشان می‌دهد در آن زمان ریاضیدانان مدل‌های آماری تهیه می‌کردند و در اختیار سرداران نظامی قرار می‌دادند تا برای تصمیم‌گیری در میدان‌های جنگ استفاده گردد [1].

به نظر می‌رسد در سده اخیر برای اولین بار اصطلاح علم‌داده توسط پیتر ناور^۱ مطرح شد. وی در سال ۱۹۶۰ میلادی علم‌داده را به جای علم کامپیوتر به کار برد. ناور بعدها اصطلاح "داده‌شناسی"^۲ را بدین منظور معرفی کرد و در سال ۱۹۷۴ در مقاله‌ای با عنوان "بررسی دقیق روش‌های کامپیوتری" از اصطلاح علم‌داده برای بیان پردازش‌های داده‌که در آن دوران در زمینه‌های وسیعی کاربرد داشت، استفاده کرد [2]. در سال ۱۹۹۶، اعضای "فدراسیون بین‌المللی جوامع دسته‌بندی"^۳ در گردهمایی دو سالانه خود، در شهر کوبه ژاپن گرد هم آمدند. در این گردهمایی اصطلاح علم‌داده توسط چیبوی هواشی^۴ معرفی شد و از آن پس علم‌داده به‌عنوان "علم‌داده، دسته‌بندی و روش‌های مرتبط" استفاده گردید [3].

در نوامبر سال ۱۹۹۷، سی‌اف‌جف وو^۵ در افتتاحیه همایشی در حوزه علم‌داده، سخنرانی خود را با عنوان "آمار یا علم‌داده" در دانشگاه میشیگان ارائه داد [4]. وی در این سخنرانی از کارهای آماری با عنوان سه‌گانه ی "گردآوری، مدل‌سازی و تحلیل داده" یاد کرد و میان علم‌داده و دانش آمار پیوند و نزدیکی برقرار کرد. در

¹ Peter Naur

² datalogy

³ International Federation of Classification Societies | IFCS

⁴ Chikio Hayashi

⁵ C. F. Jeff Wu

این راستا، جف وو نام آمار را به علم داده و آماردان را به دانشمندان داده تغییر داد. ویلیام کلیولند^۱ در سال ۲۰۰۱ در مقاله خود به نام "علم داده" برنامه‌ای برای گسترش جنبه‌های فنی در رشته آمار پیشنهاد کرد تا علم داده به‌عنوان یک رشته مستقل شناخته شود. کلیولند این رشته جدید را مرتبط با علم کامپیوتر و داده‌کاوی می‌دانست [5]. وی بر این باور بود که منافع استفاده از یک تحلیلگر داده محدود است؛ زیرا از یک سو مهندسين کامپیوتر شناخت محدودی نسبت به روش‌های کار با داده دارند و از سوی دیگر دانش محاسباتی متخصصین آمار محدود است. بنابراین تلفیق این دو گروه می‌تواند منجر به نوآوری‌های بیشتری در زمینه علم داده گردد. برای تحقق این مقصود، کلیولند پیشنهاد داد تا اساتیدی در دپارتمان‌های علم داده فعالیت کنند که قادر باشند دانش داده را با دانش محاسبات تلفیق کنند. در سال ۲۰۰۷ "جیم گری"^۲ برنده جایزه تورینگ، علم داده را به‌عنوان چهارمین پارادایم علم معرفی کرد که از تحلیل نتایج اجرای محاسبات بر روی داده‌ی بزرگ حاصل می‌شود؛ در کاربرد اخیر علم داده روشی است که در آن می‌توان با استفاده از داده‌های موجود، دانش جدیدی را بنا نهاد و آمار جدیدی را تولید کرد [6].

دی جی پاتیل^۳ در سال ۲۰۱۲ در مقاله "دانشمندان داده: جذاب‌ترین شغل قرن ۲۱" که در مجله "کسب و کار" هاروارد منتشر شد، ادعا کرد که همراه با جف همبر باکر^۴ برای اولین بار این عبارت را در سال ۲۰۰۸ برای معرفی شغل خود در لینکدین و فیس‌بوک ابداع کرده‌اند. وی از دانشمندان داده به‌عنوان نسلی جدید یاد کرد که فقدان آن‌ها منجر به محدودیت‌های جدی در بخش‌هایی از صنعت و دانشگاه می‌شود [7]. از دیگر نمونه‌های اهمیت و گسترش علم داده می‌توان به انجمن آمار آمریکا اشاره کرد که عنوان ژورنال خود را به "تحلیل‌های آماری و داده‌کاوی: تغییر نام داده، مدتی بعد و طی تغییر نامی دوباره، نام بخش اول این ژورنال به "یادگیری آماری و علم داده" مبدل شد [8].

در سال ۲۰۱۵ چاپ "مجله بین‌المللی علم و تحلیل داده" توسط اسپرینگر^۵ به‌منظور انتشار کارهای انجام شده در حوزه علم داده و تحلیل داده‌ی کلان آغاز شد و در سپتامبر همان سال طی سومین اجلاس ECDA در دانشگاه اسکس^۶ عبارت «Gesellschaft für Klassifikation» به نام انجمن علم داده افزوده شد [9].

¹William Klio Land

²Jim Gray

³Dhanurjay "DJ" Patil

⁴Jeff Hammerbacher

⁵springer

⁶Essex

۲-۳- تعریف علم داده

در زبان فارسی کلمه لاتین "science" به علم و "data" به داده ترجمه می شود. از ترکیب این دو کلمه به علم داده یاد می شود. علم داده^۱ دانشی میان رشته‌ای است که متمرکز بر استخراج دانش و علم از مجموعه‌ی داده‌ی موجود است. علم داده در واقع دانشی است که از ترکیب داده، تحلیل و استنتاج از آن به دست می‌آید؛ یا به عبارت بهتر دانشی است که با ساختار معینی از اطلاعاتی که مبتنی بر آزمایش و واقعیت است و با استفاده از پیش‌بینی و الگوریتم به دست می‌آید [10]. علم داده از ترکیب مباحث مختلفی به وجود آمده و بر مبانی و روش‌های موجود در حوزه‌های مختلف علمی بنا شده است. تعدادی از این حوزه‌ها عبارت‌اند از: ریاضیات، آمار، مهندسی داده، باز ساخت الگو و هدف این علم، استخراج مفاهیم جدید از داده و تولید "دانش جدید" داده محور است.

علم داده به شدت در سال‌های اخیر رشد داشته است. نه تنها افزایش حجم داده، بلکه فرآیندهای موجود در علم داده، منجر به تولید دانش شده است و این چرخه تبدیل داده به دانش نیز خود به رشد مضاعف این علم کمک شایان توجهی کرده است.

علم داده در موضوعات بسیار گسترده‌ای کاربرد دارد؛ در فضاوردی، پزشکی و حتی زندگی روزمره استفاده می‌شود. بشر هر روزه از تکنولوژی استفاده می‌کند و تکنولوژی و سرویس‌های مبتنی بر آن می‌تواند اطلاعات کاربری افراد را جمع‌آوری کند.

گسترده‌تر شدن داده فقط در مقدار و حجم داده نبوده، بلکه تعداد متغیرهای هر مجموعه داده نیز رشد یافته است و این امر سبب گسترش علم داده در ابعاد گوناگون با سرعت زیادی گردیده است. لازم به ذکر است که علاوه بر رشد کمی داده از جنس عدد و رشته، در سال‌های اخیر داده از جنس‌های دیگر، مانند: محتوای اینترنتی، محتوای چندرسانه‌ای و ... نیز تولید و گسترش یافته است. در گزارش IBM آمده: «۷۵٪ داده‌ی تولیدشده، ساختار نیافته و منابعی مانند: متن، صدا و ویدئو هستند» [11]. بنابراین گسترش استفاده انسان‌ها از تکنولوژی و تولید محتوا از یک سو و به کارگیری الگوریتم‌های آماری و گسترش محاسبات ریاضی از سوی دیگر سبب رشد چشم‌گیر علم داده شده است.

¹ Data Science

۲-۴- متخصص علم داده^۱

به شاغلین در حوزه‌ی علم داده، متخصص علم داده یا دانشمند داده می‌گویند. دانشمند داده کسی است که دارای مهارت‌هایی مثل تحلیل داده، مدل‌سازی و آمار باشد. در کنار این مهارت‌ها، کار دیگری هم جزو وظایف اصلی یک متخصص داده است، که از آن به‌عنوان مرتب‌سازی داده یاد می‌شود. به‌طور خلاصه منظور از مرتب‌سازی داده این است که متخصص این دانش بتواند داده‌ی بهم‌ریخته را ابتدا مرتب و منظم کرده و سپس به بررسی آن‌ها بپردازد [12] که در ادامه تک‌تک این وظایف را به‌صورت موردی بررسی کند.

چن فو جف وو در سال ۱۹۹۸ برای اولین بار در یک سخنرانی از واژه‌ی متخصص علم داده استفاده کرد. متخصصین علم داده با تعمق در چندین رشته‌ی علمی، مسائل پیچیده‌ی مطرح‌شده در حوزه‌ی داده را حل می‌کنند. به‌طور کلی انتظار می‌رود که متخصصین علم داده قادر باشند در بخش‌هایی از علم ریاضیات، آمار و کامپیوتر کار کنند. یک متخصص علم داده می‌بایست در یک یا دو رشته تخصص داشته باشد و در دیگر حوزه‌ها دارای مهارت کافی باشد.

برخی معتقدند متخصص علم داده توسط دی جی پاتیل و جف هم‌بارکر ابداع شده است. دی جی پاتیل در سال ۲۰۱۲ در مقاله "علم داده: جذاب‌ترین شغل قرن بیست و یکم" متخصصین علم داده را این‌طور تعریف می‌کند: کسانی که می‌دانند چگونه می‌توان از انبوه اطلاعات بدون ساختار، پاسخ سؤال‌های کسب و کار را پیدا کرد.

استنتون در سال ۲۰۱۳ در تعریف علم داده به مهارت‌های لازم برای متخصص بودن در این علم اشاره می‌کند: علم داده رشته‌ی در حال ظهوری است که به جمع‌آوری، آماده‌سازی، تحلیل، بصری‌سازی، مدیریت و نگهداشت اطلاعات در حجم بالا می‌پردازد.

دریسکول در سال ۲۰۱۴ در تعریف علم داده و متخصص آن می‌نویسد: علم داده مهندسی ساختمان داده است. و متخصص علم داده دانشی کاربردی از داده و ابزارها دارد. به‌علاوه درک تئوری دارد که مشخص می‌کند چه چیزی از نظر علمی ممکن است [13].

بدین ترتیب هرکسی که به یافتن موقعیت شغلی قدرتمندتر در این حوزه علاقه‌مند است، باید مهارت‌های کلیدی در سه زمینه تحلیل، برنامه‌نویسی و دانش مربوط به حوزه مورد استفاده را کسب کند. با نگاهی عمیق‌تر، می‌توان گفت مهارت‌های زیر می‌تواند به افراد جهت تبدیل شدن به یک دانشمند داده کمک کند:

¹ Data Scientist